



TU Clausthal

Entwurf einer modellprädiktiven Regelung
zur Klimatisierung batterieelektrischer Fahrzeuge
durch Verfahren des maschinellen Lernens

DISSERTATION

Zur Erlangung des Grades eines
Doktors der Ingenieurwissenschaften

vorgelegt von

Peter Engel

aus

Brandenburg an der Havel

Genehmigt von der Fakultät für
Mathematik/Informatik und Maschinenbau
der Technischen Universität Clausthal

Tag der mündlichen Prüfung

05.11.2020

Dissertation Clausthal, SSE-Dissertation 23, 2020

Dekan

Prof. Dr.-Ing. Volker Wesling

Vorsitzender der Promotionskommission

Prof. Dr. Jörg P. Müller

Betreuer

Prof. Dr. Andreas Rausch

Gutachter

Prof. Dr.-Ing. Harald Ludanek

Prof. Dr.-Ing. Christian Bohn

Danksagung

Hiermit möchte ich mich bei allen, die mich bei der Erstellung dieser Arbeit unterstützt und begleitet haben, herzlich bedanken. Mein ganz besonderer Dank gilt in erster Linie meinem Betreuer Prof. Dr. Andreas Rausch für die intensive Betreuung über alle Phasen der Promotion von der Themenfindung bis zur Fertigstellung der Arbeit.

Des Weiteren danke ich Prof. Dr.-Ing. Harald Ludanek und Prof. Dr.-Ing. Christian Bohn für die Bereitschaft der Übernahme der Gutachten und für die Anmerkungen zur Verbesserung der Arbeit. Ich danke auch Herrn Prof. Dr. Jörg P. Müller für die Übernahme des Vorsitzes der Prüfungskommission.

Ebenso bedanke ich mich bei Arthur Strasser und Sebastian Meise, die mit mir zahlreiche Fragestellungen der Arbeit intensiv diskutiert, umfangreiche Teile der Arbeit Korrektur gelesen und so wesentlich zum Gelingen beigetragen haben. Des Weiteren danke ich Dr. Stefanie Jauns-Seyfried für die Korrektur großer Teile der Arbeit.

Für die zahlreichen Diskussionen, fachlichen Ratschläge und das Feedback zur Arbeit danke ich Dr. Marko Körner, Dr. Malte Mauritz, Prof. Dr. Falk Howar, Dr. Christoph Knieke, Axel Grewe, Christian Ristig, Christoph Fieber, Henrik Peters, Jörg Grieser, Dr. Andreas Schulze, Thorben Knust, Phillip Wolter, Dirk Herrling, Karl-Falco Storm, Meng Zhang, Fadi Jabbour, Leonard Scholz, Adina Aniculaesei, Mirco Schindler, Stefan Wittek, Dimitri Bratzel, Steffen Küpper, Karina Rehfeldt, Dr. Christian Bartelt, Sebastian Lawrenz, Priyanka Sharma, Daning Wang, Dr. Thomas Oszinda und Vladislav Taratunin.

Ich danke des Weiteren Thomas Bravin und Igor Melkozerov für die technische Unterstützung, sowie den studentischen Hilfskräften Nadezda Buneeva und Sergey Bondarev für die Literaturrecherchen.

Abschließend bedanke ich mich bei allen übrigen Kollegen des ISSE und des DIGITs, die während der Erstellung dieser Dissertation stets für eine angenehme Arbeitszeit gesorgt haben und mir immer mit Rat und Tat zur Seite standen.

Kurzbeschreibung

Im Vergleich zu verbrennungsmotorisch betriebenen Fahrzeugen weisen batterieelektrisch betriebene Elektrofahrzeuge (BEV) eine signifikant geringere Reichweite auf. Die Innenraumklimatisierung stellt neben dem Antrieb den zweitgrößten Verbraucher in Elektrofahrzeugen dar. Eine Optimierung im Sinne von Maßnahmen zur Reduzierung des Energiebedarfs der Innenraumklimatisierung kann daher wesentlich zur Reichweitensteigerung und somit auch der Marktdurchdringung dieser Technologie beitragen. Der Einsatz einer intelligenten Betriebsstrategie stellt eine kostengünstige Möglichkeit dar, die Effizienz des Gesamtsystems zu steigern und so zur Steigerung der Reichweite batterieelektrisch betriebener Elektrofahrzeuge beizutragen. Ein Ansatz zur Ausschöpfung des vorhandenen Optimierungspotentials im Bereich der Fahrzeugklimatisierung ist die Verwendung Modelprädiktiver Regelungen.

Der Realisierung einer auf diesem Ansatz basierenden Regelung der Fahrzeugklimatisierung stehen mehrere Herausforderungen entgegen. Die wesentliche Voraussetzung für ein befriedigendes Regelungsverhalten ist die hinreichend genaue Vorhersage der betroffenen Regel- und Zustandsgrößen. Werden durch eine unzureichende Berücksichtigung von Störgrößen und durch eine unzureichende Modellierung der ablaufenden technischen Prozesse Regelgrößen falsch vorhergesagt, so werden die Regelabweichungen ebenfalls falsch vorhergesagt, weshalb vorhandenes Optimierungspotential nicht ausgeschöpft werden kann. Methoden des maschinellen Lernens wie z.B. tiefe rekurrente neuronale Netze bieten hierbei eine Alternative zur konventionellen theoretischen, experimentellen oder hybriden Modellbildung.

Im Rahmen dieser Arbeit wurde für eine temperaturgeführte Regelung einer Einzonen-Klimaanlage ein Lösungskonzept zur Umsetzung eines modellprädiktiven Ansatzes basierend auf Verfahren des maschinellen Lernens entwickelt. Der Fokus lag hierbei auf einer Reduzierung des Energiebedarfs bei gleichzeitiger Erfüllung der übernommenen Anforderungen an die konventionelle Regelung. Das Vorgehen in dieser Arbeit basiert auf dem Ist-Zustand-orientierten Vorgehen im Mikrozyklus gemäß VDI-Richtlinie 2206. Ausgehend vom Entwicklungsziel wurde zunächst eine Situationsanalyse des bestehenden Systems durchgeführt. Hierbei wurde, ausgehend von den übernommenen Anforderungen an die konventionelle Regelung, eine Untersuchung der Regelgüte und des Energiebedarfs eines Referenzsystems durchgeführt. Als Referenzsystem diente ein in Zusammenarbeit mit der TLK-Thermo GmbH erstelltes thermisches Gesamtfahrzeugmodell eines BEV. Zur Modellvalidierung wurden reale Straßenversuche mit einem VW-e-Golf durchgeführt. Die Bewertung der Energieeffizienz erfolgte anhand abgeleiteter Versuchsszenarien aus klimatischen Daten und Pkw-Nutzungsverhalten in Deutschland. Für diese Versuchsszenarien wurden Simulationen am FMU-basierten thermischen Gesamtfahrzeugmodell durchgeführt. Mit den Ergebnissen dieser Untersuchung erfolgte eine Zielformulierung und Anforderungsableitung an den Systementwurf. Hierauf aufbauend wurde ein Grobkonzept für eine modellprädiktive temperaturgeführte Regelung einer Einzonen-Klimaanlage entworfen. Auf Basis dieses Grobkonzepts wurden Untersuchungen zu Lösungsansätzen für die Teilsysteme des Gesamtsystems durchgeführt. Hierfür wurden unter anderem Modelle zur Störgrößenprognose sowie ein Modell zur Abbildung des physikalischen Verhaltens auf Basis von Verfahren des maschinellen Lernens entwickelt. Für die Optimierung der Stellgrößen wurde ein Optimalsteuerungsproblem durch ein Gütefunktional formuliert und zur Lösung der Optimierungsaufgabe ein Verfahren basierend auf evolutionären Algorithmen entwickelt. In einer anschließenden Systemsynthese wurden die entwickelten Teilfunktionen zu einem Gesamtsystem integriert und durch experimentelle Untersuchungen im Vergleich zum bestehenden System mit konventioneller Regelung bewertet.

Inhaltsverzeichnis

I.	Abbildungsverzeichnis.....	V
II.	Tabellenverzeichnis.....	VII
III.	Abkürzungsverzeichnis.....	IX
1	Einleitung.....	1
1.1	Motivation und Zielsetzung.....	1
1.2	Stand der Technik.....	3
1.3	Forschungsfrage.....	6
1.4	Aufbau der Arbeit.....	7
2	Grundlagen.....	9
2.1	Modellbildung technischer Prozesse.....	9
2.1.1	Grundlagen der Modellbildung.....	9
2.1.1.1	Vorgehensweise der Modellierung.....	10
2.1.1.2	Dynamische und statische Modelle.....	11
2.1.1.3	Lineare und nichtlineare Modelle.....	11
2.1.1.4	Kontinuierliche und diskrete Modelle.....	11
2.1.1.5	Zeitvariante und zeitinvariante Systeme.....	11
2.1.1.6	Deterministisch und stochastische Modelle.....	11
2.1.1.7	Kausale und akusale Modelle.....	12
2.1.1.8	Modelle mit konzentrierten oder verteilten Parametern.....	13
2.1.2	Klassische Modellbildung von Regelstrecken.....	14
2.1.3	Thermodynamische Grundlagen.....	16
2.1.3.1	Wärmestrom und Wärmetransport.....	16
2.1.3.1.1	Konvektion.....	17
2.1.3.1.2	Wärmeleitung.....	18
2.1.3.1.3	Strahlung.....	19
2.1.3.2	Enthalpieströme.....	22
2.1.3.3	Relative Luftfeuchte und Taupunkt.....	23
2.1.4	Experimentelle Modellbildung durch künstlich neuronale Netze.....	24
2.1.4.1	Einlagige Perzeptrons.....	24
2.1.4.2	Feed-Forward-Netze.....	27
2.1.4.3	Rekurrente Netze.....	31
2.2	Grundlagen der modellprädiktiven Regelung.....	35
2.2.1	Lineare modellprädiktive Regelung ohne Begrenzungen.....	37

2.2.2	Lineare modellprädiktive Regelung mit Begrenzungen	41
2.2.3	Nichtlineare modellprädiktive Regelung mit Begrenzungen	44
3	Fahrzeugklimatisierung	51
3.1	Entwicklungsmethodik	51
3.2	Anforderungen an Kfz-Klimaanlagen	56
3.3	Aufbau und Funktionsweise von Fahrzeugklimaanlagen.....	59
3.4	Regelung von Kfz-Klimaanlagen	62
3.4.1	Regelung des Kältemittelkreislaufs	63
3.4.2	Regelung des Heizkreislaufs	63
3.4.3	Innenraumtemperaturregelung	64
3.4.4	Regelung des Kühlkreislaufs	64
3.4.5	Regelung von Umluftklappe und Frischluftgebläse.....	65
4	Situationsanalyse und Zielformulierung.....	67
4.1	Konventionelle Modellbildung	68
4.2	Situationsanalyse.....	72
4.2.1	Design of Experiment	72
4.2.2	Bewertung der konventionellen Regelung.....	76
4.2.2.1	Bewertung der Abweichung von Soll- und Ist-Kabinentemperatur	76
4.2.2.2	Bewertung von Grenzwertverletzungen	81
4.2.2.3	Bewertung des Energiebedarfs	82
4.2.2.4	Zusammenfassende Bewertung	84
4.3	Zielformulierung	86
5	Systemsynthese- und Analyse	89
5.1	Konzept der Lernenden Modellprädiktiven Regelung (Grobkonzept)	89
5.2	Modellbildung durch Verfahren des maschinellen Lernens	91
5.2.1	Modellbildung des Prozessmodells	93
5.2.1.1	Phase 1 - Process Understanding	93
5.2.1.2	Phase 2 - Data Understanding	93
5.2.1.3	Phase 3 - Data Preparation.....	94
5.2.1.4	Phase 4 - Modeling	96
5.2.1.5	Phase 5 - Evaluation	98
5.2.1.6	Phase 6 - Deployment	98
5.2.2	Modellbildung der Störgrößenmodelle	99
5.2.2.1	Phase 1 - Process Understanding	99
5.2.2.2	Phase 2 - Data Understanding	101

5.2.2.3	Phase 3 - Data Preparation.....	105
5.2.2.4	Phase 4 - Modeling.....	106
5.2.2.4.1	Geschwindigkeit und Verweildauer	106
5.2.2.4.2	Temperatur	108
5.2.2.4.3	Solare Strahlung	111
5.2.2.5	Phase 5 - Evaluation	112
5.2.2.6	Phase 6 - Deployment	112
5.3	Lokale und externe Datenverwaltung.....	113
5.3.1	Abruf, Aufbereitung und Bereitstellung der Trainingsdaten.....	113
5.3.1.1	Daten des Prozessmodells.....	113
5.3.1.2	Daten der Störgrößenmodelle.....	113
5.3.2	Abruf, Aufbereitung und Bereitstellung der Prognoseinputdaten.....	117
5.4	Prädiktion von Stell- und Störgrößen.....	118
5.5	Modellprädiktive Optimierung.....	119
5.5.1	Entwurf des Kritikers	122
5.5.2	Entwurf der Optimierungssteuerung	124
5.5.2.1	Initialisierung	125
5.5.2.2	Evolutionsprozess.....	125
5.5.2.2.1	Rekombination und Mutation.....	125
5.5.2.2.2	Evaluation und Selektion.....	127
5.5.2.2.3	Anpassung der Evolutionsparameter.....	128
5.5.2.3	Bereitstellung der Lösung.....	129
5.6	Systemsynthese.....	130
6	Analyse und Bewertung	133
6.1	Experimentelle Untersuchung.....	134
6.1.1	Erreichung der Optimierungsziele.....	134
6.1.2	Lernfähigkeit des Verfahrens	139
6.2	Entscheidung	140
7	Zusammenfassung und Ausblick	141
A.	Anhang	157

I. Abbildungsverzeichnis

Abbildung 1 Aufbau der Arbeit	7
Abbildung 2 Wärmeströme an einer Fahrzeugkabine	17
Abbildung 3 Wärmeströme an der Fahrzeugkabinenwand	18
Abbildung 4 Vergleich der gemessenen und berechneten solaren Bestrahlungsintensität	19
Abbildung 5 Aufbau einer rekurrenten (Gedächtnis)-Zelle	31
Abbildung 6 Aufrollen einer Sequenz innerhalb einer Zelle	32
Abbildung 7 Aufbau einer LSTM-Zelle	33
Abbildung 8 Aufrollen einer Sequenz innerhalb einer LSTM-Zelle	34
Abbildung 9 Wirkungsablauf der modellprädiktiven Regelung	35
Abbildung 10 Ablauf der modellprädiktiven Regelung bei konstantem Sollwert	36
Abbildung 11 Prinzip der modellprädiktiven Regelung mit Referenztrajektorie	37
Abbildung 12 Quality Gates im Produktentstehungsprozess [91]	51
Abbildung 13 PEPs einzelner Hersteller und Referenzmodell nach Göpfert [87]	52
Abbildung 14 Fahrzeugspezifischer Produktentstehungsprozess nach Göpfert [87]	53
Abbildung 15 V-Modell als Problemlösungszyklus auf Makroebene gem. VDI Richtlinie 2206 [92]	54
Abbildung 16 Anzustrebende mittlere Lufttemperatur gem. DIN 1946:3	56
Abbildung 17 Prinzipdarstellung der Luftführung im Klimagerät	59
Abbildung 18 Funktionsweise des Kühlkreislaufs	60
Abbildung 19 Funktionsweise des Heizkreislaufs	61
Abbildung 20 Prinzip der innenraumtemperaturgeführten Regelung einer Klimaanlage	62
Abbildung 21 Wirkungsablauf Verdichterregelung	63
Abbildung 22 Wirkungsablauf Heizkreisregelung	64
Abbildung 23 Wirkungsablauf Innenraumtemperaturregelung	64
Abbildung 24 Wirkungsablauf Kühlkreisregelung	65
Abbildung 25 Vorgehen im Mikrozyklus gem. VDI Richtlinie 2206	67
Abbildung 26 Modell des Kältesystems [55]	68
Abbildung 27 Kopplung der Wärmeströme im Innenmodell des Fahrzeugkabinensystems	69
Abbildung 28 Geschwindigkeitsprofil gem. Prüfzyklus WLTC Klasse 2	73
Abbildung 29 Auswahl von Ein- und Ausgangsgrößen des Versuchsszenarios Nr. 199	75
Abbildung 30 Temperatur- und Stellgrößenverläufe im Versuchsszenario Nr. 2	76
Abbildung 31 Temperatur- und Stellgrößenverläufe im Versuchsszenario Nr. 12	77
Abbildung 32 Temperatur- und Stellgrößenverläufe im Versuchsszenario Nr. 44	77
Abbildung 33 Temperatur- und Stellgrößenverläufe im Versuchsszenario Nr. 144	78
Abbildung 34 Temperatur-, Strahlungs- und Stellgrößenverläufe im Versuchsszenario Nr. 336	79
Abbildung 35 Temperatur-, Strahlungs- und Stellgrößenverläufe im Versuchsszenario Nr. 288	80
Abbildung 36 Temperatur-, Strahlungs- und Stellgrößenverläufe im Versuchsszenario Nr. 194	81
Abbildung 37 Temperatur-, Strahlungs- und Stellgrößenverläufe im Versuchsszenario Nr. 426	82
Abbildung 38 Fachliche Architektur des Gesamtsystems	90
Abbildung 39 Untergliederung der Teilfunktion Trainer	91
Abbildung 40 Vorgehen zur Modellentwicklung in Anlehnung an das CRISP-DM-Vorgehensmodell ..	92
Abbildung 41 Generierte Testsignale für Umgebungstemperatur und Zustand ACC	95
Abbildung 42 Verlauf der prädizierten Ausgangsgrößen	97
Abbildung 43 Antwort einer Routenplanungsabfrage mit graphhopper	101

Abbildung 44 Antwort des Wetterdienstes auf die Abfrage des aktuellen Wetters	102
Abbildung 45 Antwort des Wetterdienstes auf die Abfrage einer Wettervorhersage	103
Abbildung 46 OpenWeather-Wetterstationen auf der Strecke Goslar-Clausthal.....	104
Abbildung 47 Vergleich Geschwindigkeitsprognose GraphHopper mit einer Messung (vgl. [125])...	105
Abbildung 48 Geschwindigkeitsprognose mit wkNN-Ansatz (vgl. [125]).....	107
Abbildung 49 Vergleich abgefragter Wetterdaten mit Fahrzeugmessdaten	108
Abbildung 50 Zeitlicher Versatz von Vorhersagezeit und Messung.....	109
Abbildung 51 Vergleich von Messung und Temperaturvorhersage (vgl. [125])	110
Abbildung 52 Vorhersage und Messung der solaren Strahlung (vgl. [125])	111
Abbildung 53 Graphische Darstellung der verwendeten Definitionen	114
Abbildung 54 Messpunkte und Segmente einer Beispielfahrt.....	115
Abbildung 55 Datenmodell zur Ablage der Wetter- und Messdaten.....	116
Abbildung 56 Untergliederung der Teilfunktion Prädiktor	118
Abbildung 57 Untergliederung der Teilfunktion Modellprädiktiver Optimierer.....	119
Abbildung 58 Prinzipieller Ablauf evolutionärer Algorithmen	121
Abbildung 59 Bestrafung von Grenzwertverletzungen bei verschiedenen Strafparametern.....	123
Abbildung 60 Ablauf der Optimierungssteuerung	124
Abbildung 61 Ablauf des Mutationsverfahrens	126
Abbildung 62 Darstellung der ACC-Trajektorie im Problem- und Suchraum	127
Abbildung 63 Veränderung der Lösung im Optimierungsprozess	129
Abbildung 64 Temperatur- und Stellgrößenverläufe im Versuchsszenario 193	130
Abbildung 65 Temperatur- und Stellgrößenverläufe im Versuchsszenario 237	131
Abbildung 66 Ablauf des zweiten Analyseschrittes	133
Abbildung 67 Temperatur-, Strahlungs- und Stellgrößenverläufe im Versuchsszenario Nr. 336	134
Abbildung 68 Häufigkeit der Verbesserung/Verschlechterung im Vergleich zur konv. Regelung	135
Abbildung 69 Zielerreichung mit initial trainiertem Prozessmodell	136
Abbildung 70 Temperatur-, Leistungs- und Stellgrößenverläufe im Versuchsszenario Nr. 268	137
Abbildung 71 Temperatur-, Leistungs- und Stellgrößenverläufe im Versuchsszenario Nr. 426	138
Abbildung 72 Zielerreichung mit initial trainiertem und nachtrainiertem Prozessmodell	139

II. Tabellenverzeichnis

Tabelle 1 Häufig verwendete Aktivierungsfunktionen.....	25
Tabelle 2 Klimabeurteilungsskala des PMV gem. DIN EN ISO 7730.....	57
Tabelle 3 Bewertung der Luftqualität nach CO ₂ -Konzentration gem. DIN EN 13779	58
Tabelle 4 Ein- und Ausgangsgrößen des Gesamtmodells.....	70
Tabelle 5 Betrachtende funktionale und nichtfunktionale Anforderungen an das Regelungssystem .	72
Tabelle 6 Metriken zur Überprüfung der Anforderungen.....	72
Tabelle 7 Metriken zur Bewertung der Energieeffizienz.....	73
Tabelle 8 Prozentuales Auftreten der Klimacluster für Gesamteuropa in Anlehnung an [111]	74
Tabelle 9 Kennwerte der Verdichterleistung	82
Tabelle 10 Kennwerte der PTC-Heizelement-Leistung.....	83
Tabelle 11 Kennwerte der Gesamtleistung.....	83
Tabelle 12 Prozentuale Reichweitenreduktion	83
Tabelle 13 Reichweitenreduktion in Kilometern.....	84
Tabelle 14 Teilfunktionen des Gesamtlösungsansatzes.....	89
Tabelle 15 Spezifikation der Testsignale	94
Tabelle 16 Gewählte Hyperparameter	97
Tabelle 17 Zusammenfassung der Metriken des initialen Lernvorgangs.....	98
Tabelle 18 Konfidenzintervalle der Prognosefehler für verschiedene Wahrscheinlichkeiten	98
Tabelle 19 Festgelegte Evolutionsparameter.....	128

III. Abkürzungsverzeichnis

ACC	Air Conditioning and Cooling
AD	Automatisches Differenzieren
ADAM	Adaptive Moment Optimization
ANN	Artificial Neural Network
API	Application Programming Interface
BEV	Battery Electric Vehicle
BFGS	Broyden-Fletcher-Goldfarb-Shanno - (Algorithmus)
BLF	Binary Logging Format
BPTT	Backpropagation Through Time
CAN	Controller Area Network
CFD	Computational Fluid Dynamics
COP	Coefficient of Performance
DAE	Differential-Algebraic System of Equations
DFP	Davidon-Fletcher-Powell - (Formel)
DWD	Deutscher Wetterdienst
ELU	Exponential Linear Unit
EOOT	Equation Based and Object-Oriented Tools
FAT	Forschungsvereinigung Automobiltechnik
FDM	Finite-Differenzen-Methode
FEM	Finite-Elemente-Methode
FMI	Functional Mock-Up Interface
FMU	Functional Mock-Up Unit
FVM	Finite-Volumen-Methode
GAN	Generative Adversarial Networks
GFS	Global Forecast System
HiL	Hardware in the Loop
HLK	Heizung-, Lüftungs- und Klimaanlage
HV	Hochvolt (-System)
HVAC	Heating, Ventilation and Air Conditioning
IDA	Indoor Air (Quality)
KKT	Karush-Kuhn-Tucker - (Bedingungen)
KNN	Künstliches neuronales Netz
LMS	Least Mean Squares
LSTM	Long Short Term memory
LZI	Lineares zeitinvariant
MBPC	Model Based Predictive Control
MEZ	Mitteuropäische Zeit
MiL	Model in the Loop
ML	Machinelles Lernen/Machine Learning
MLP	Mehrlagiges Perzeptron/Multilayer Perceptron
MPC	Model Predictive Control
MAE	Mean Absolute Error
NARX	Nonlinear Autoregressive Networks with Exogenous Inputs
NMPC	Nonlinear Model Predictive Control

NOAA	National Oceanic and Atmospheric Administration
NWM	Numerisches Wettermodell
ODE	Ordinary Differential Equation
OEM	Original Equipment Manufacturer
OSM	OpenStreetMap
PEP	Produktentstehungsprozess
PID	Proportional-Integral-Differential - (Regler)
PiL	Prozessor in the Loop
PMV	Predicted Mean Vote
PTC	Positive Temperature Coefficient - (Thermistor)
PWM	Pulsweitenmodulation
ReLU	Rectified Linear Unit
RMSE	Root Mean Square Error
RMSProp	Root Mean Square Propagation
SARIMA	Seasonal Autoregressive and Moving Average
SELU	Scaled Exponential Linear Unit
SGD	Stochastic Gradient Descent
SiL	Software in the Loop
SMPC	Stochastic Model Predictive Control
SOH	State of Health
SQP	Sequential Quadratic Programming
TMY	Typical Meteorological Year
wKNN	Weighted k-Nearest-Neighbor - (Verfahren)
WLTC	Worldwide Harmonized Light Duty Test Cycle
WOZ	Wahre Ortszeit
XiL	X in the Loop
ZGL	Zeitgleichung

1 Einleitung

1.1 Motivation und Zielsetzung

Im Jahr 2019 wurden in Deutschland 63300 rein elektrisch betriebene Personenkraftwagen neu zugelassen. Dies entspricht bei insgesamt 3,61 Millionen neu zugelassenen PKW, lediglich einem Marktanteil von 1,75%. Die Ursachen der geringen Marktdurchdringung dieser Technologie liegen im Wesentlichen in der unzureichenden Ladeinfrastruktur, der Ladedauer, der begrenzten Reichweite und an den hohen Kosten batterieelektrisch betriebener Elektrofahrzeuge (BEV). Die im Vergleich zu verbrennungsmotorisch betriebenen Fahrzeugen signifikant geringere Reichweite lässt sich im Wesentlichen auf zwei Faktoren zurückführen. Der erste Faktor ist in der deutlich geringeren Energiedichte des Energieträgers begründet. Während heutige Lithium-Ionen-Akkumulatoren für BEV Energiedichten von 0,15 kWh/kg bis zu 0,3 kWh/kg aufweisen, beträgt die Energiedichte z.B. von Dieselmotoren 11,9 kWh/kg. Hierdurch wird die maximal mitführbare Energiemenge stärker limitiert und ein erhöhter Antriebsenergiebedarf aufgrund des höheren Gewichts verursacht. Den zweiten Faktor stellt die geringe Abwärme des Elektromotors dar. Um den Fahrgastraum zu klimatisieren, sind elektrisch betriebene Nebenaggregate erforderlich, deren Energiebedarf zusätzlich mitgeführt werden muss. Die Innenraumklimatisierung stellt neben dem Antrieb den zweitgrößten Verbraucher in Elektrofahrzeugen dar. Der Energiebedarf für Heizen, Kühlen und Belüftung kann die Reichweite erheblich reduzieren [1] [2]. Bei einem Volkswagen e-Golf ergibt sich z.B. unter extremen Wetterbedingungen eine Verringerung der maximalen Reichweite von bis zu ca. 30%¹.

Eine Optimierung auf diesem Gebiet im Sinne von Maßnahmen zur Reduzierung des Energiebedarfs der Innenraumklimatisierung kann daher wesentlich zur Reichweitensteigerung und somit auch der Marktdurchdringung dieser Technologie beitragen. Eine Reihe aktiver und passiver Maßnahmen zur Reduzierung des Energiebedarfs der Klimatisierung von Elektrofahrzeugen sind bereits Stand der Technik. Passive Maßnahmen wie Dämmung des Dachhimmels, Sonnenstrahlreflexionstechnik, Infrarotlichtreflektierende Scheiben, thermische Dämmung der Karosseriefächen oder der Einbau von Isolierglasscheiben haben gegenüber den aktiven Maßnahmen den Vorteil, dass hierfür keine zusätzliche Energie aufgewendet werden muss [3] [4]. Aktive Maßnahmen wie die Nutzung einer Wärmepumpe, der Verbau eines Verdampfer-Bypasses oder der Einsatz von Infrarot-Heizflächen haben den Vorteil, dass sie nicht nur dämpfend wirken, sondern dauerhaft die erzielten Effekte erreichen. Zusätzlich wurden in den letzten 20 Jahren durch eine Reihe von Detailoptimierungen, wie z.B. durch den Einsatz von geregelten Expansionsventilen an Stelle einer Drossel (Orifice Tube), weitere Maßnahmen zur Reduktion des Energiebedarfs durch die Erhöhung der Leistungszahl der Kälteanlagen (COP, Coefficient of Performance) umgesetzt. All diesen Maßnahmen ist gemein, dass sie die Fahrzeuganschaffungskosten erheblich erhöhen. Im Gegensatz hierzu bietet der Einsatz einer intelligenten Betriebsstrategie eine kostengünstige Möglichkeit die Effizienz des Gesamtsystems ohne Komforteinbußen weiter zu steigern. [5]

Ein relativ neuer Ansatz zur Ausschöpfung des vorhandenen Optimierungspotentials im Bereich der Fahrzeugklimatisierung ist die Verwendung Modelprädiktiver Regelungen (MPC). Diese Regelungen basieren auf einem mathematischen Prozessmodell, welches den Verlauf der Ausgangsgrößen bei gegebenen Eingangsgrößen für einen begrenzten Zeithorizont prädiziert. Dieses Prozessmodell wird mit

¹ Bei max. Reichweite im WLTC von 231 km, max. Nettoenergie des Akkumulators von 31,5 kWh und einer PTC-Hochvoltheizung mit einer maximalen Leistung von 5,5 kW

einem Gütefunktional und einem Optimierungsverfahren verknüpft. Durch das Gütefunktional kann die Performanz der Regelung bzgl. der Erreichung der verschiedenen Regelziele bewertet werden. Durch das Optimierungsverfahren wird durch Minimierung des Gütefunktionals über den Prädiktionshorizont die bestmögliche Trajektorie für die berücksichtigten Stellgrößen gesucht. Modellprädiktive Regelungen bieten im Gegensatz zur konventionellen Regelung eine Reihe von Vorteilen. Zum einen kann durch die vorausschauende Arbeitsweise frühzeitig auf zukünftige Abweichungen der Regelgrößen und Verletzung von Nebenbedingungen reagiert werden [6]. Zum anderen kann durch MPC eine effiziente Mehrgrößenregelung realisiert werden. Dezentrale konventionelle Regler berücksichtigen in der Regel jeweils nur ein betroffenes Stell- und Regelgrößenpaar. Bestehen starke Wechselwirkungen durch Kopplung mehrerer Stell- und Regelgrößenpaare, kann durch die dezentrale Regelung kein Gesamtoptimum erreicht oder darüber hinaus das System instabil werden. Werden mehrere konventionelle Regler z.B. durch den Einsatz von Haupt- und Entkopplungsregler zu einem Mehrgrößenregler kombiniert, steigt die Komplexität des Systems, während die Komplexität der Mehrgrößenregelung der modellprädiktiven Regelung der Komplexität einer Eingrößenregelung entspricht. Ein weiterer wesentlicher Vorteil von MPC ist die Möglichkeit, Nebenbedingungen für Eingangs-, Ausgangs- und Zustandsgrößen explizit zu spezifizieren, so dass hier Grenzwertverletzung mehrerer Größen parallel verhindert werden können. Des Weiteren bieten MPC die Möglichkeit, mit zeitverzögerten Signalen umzugehen und Wissen über zukünftige Zustände zu berücksichtigen. Aufgrund dieser Vorteile bietet sich der Einsatz von MPC für Kraftfahrzeugklimaanlagen an. Neben der Regelung der Innenraumtemperatur werden in modernen Kraftfahrzeugklimaanlagen die Luftfeuchte, die Zuluftmenge, die Zuluftverteilung und die Luftgüte geregelt. Hierbei müssen mehrere Regelziele parallel erreicht und diverse Nebenbedingungen eingehalten werden. So muss neben einer behaglichen Kabinentemperatur und Luftfeuchte, unter anderem Scheibenbeschlag, zu hoher Kohlendioxidgehalt, erhöhter Bauteilverschleiß verhindert, sowie Geräuschpegel und Schwingungen geringgehalten werden.

Den Vorteilen der modellprädiktiven Regelung stehen gerade im Hinblick auf eine Realisierung einer Regelung der Fahrzeugklimatisierung mehrere Schwachstellen entgegen. Die wesentliche Voraussetzung für ein befriedigendes Regelungsverhalten ist die hinreichende genaue Vorhersage der betroffenen Regel- und Zustandsgrößen. Wird durch unzureichende Modellierung eine Regelgröße falsch vorhergesagt, wird die Regelabweichung ebenfalls falsch vorhergesagt, weshalb die Regelung für die gegebenen Randbedingungen nicht das wahre Optimum finden kann. Die Güte der Vorhersage des zukünftigen Verhaltens der Regelgröße unterliegt zwei Unsicherheiten. Zum einen unterliegt sie der Genauigkeit des Prozessmodells und zum anderen der Berücksichtigung der Störgrößen. Da neben den Stelleingriffen auch äußere Störgrößen das System beeinflussen, ist es ebenso erforderlich, diese Störgrößen hinreichend genau zu prognostizieren. Die Güte der Gesamtsystemregelung hängt daher zu einem großen Teil von der Güte der Störgrößenprognose ab. Dies wurde in vorangegangenen Ansätzen nicht ausreichend berücksichtigt. Die zukünftigen nicht beeinflussbaren Störgrößen wurden entweder indirekt durch Kompensationsverfahren durch die Verwendung eines Beobachters behandelt und somit nicht direkt vorrausschauend berücksichtigt, im Vorfeld entweder als bekannt angenommen oder durch eine sehr schwache Schätzung vorhergesagt. Am häufigsten wird der Störgrößenverlauf über den aktuellen Prädiktionshorizont durch den letzten Messwert geschätzt. Dies ist insofern unrealistisch, da in der Realität die Außentemperatur aber auch besonders die Sonnenstrahlung über den Verlauf der Fahrt sehr dynamisch schwankt. Für die Regelung der Innenraumklimatisierung entsprechen die Störgrößen den thermischen Lasten. Diese Lasten werden im Wesentlichen durch den Energieeintrag solarer Strahlung, Außentemperatur, Windgeschwindigkeit und Luftfeuchte verursacht. Die Modellierung des Prozessmodells erfolgt in der Regel durch eine sehr aufwendige Beschreibung des komplexen

thermischen Verhaltens der verschiedenen Komponenten im Fahrzeug durch Differentialgleichungssysteme. Hierbei muss durch aufwendige Versuchsreihen eine Vielzahl von Koeffizienten für die berücksichtigten Bauteile ermittelt werden. Für jeden Fahrzeugtyp muss ein individuelles Modell erstellt werden, da sich diese in Baugruppen, Geometrien, Werkstoffen usw. unterscheiden. Veränderbare Parameter werden in der Regel durch ein solch statisches Modell nicht berücksichtigt. So werden z.B. Alterung von Lack und Material in den Koeffizienten der Baugruppen nicht berücksichtigt. Auch weitere Einflüsse wie Änderung von Geometrie und Volumen z.B. durch Einbauten oder veränderte Reflexions- und Absorptionskoeffizienten durch Staub und Schmutz werden ebenfalls nicht berücksichtigt. Eine hohe Vorhersagequalität der Ausgangsgrößen des Prozessmodells hat in der Regel eine hohe Modellkomplexität zur Folge, was zu einer weiteren Schwachstelle von MPC führt. Um komplexes thermisches Verhalten im Prozessmodell adäquat abzubilden sind nichtlineare Modelle erforderlich. Eine analytische Lösung des Optimierungsproblems ist hierbei nicht möglich, weshalb rechenaufwendige numerische Verfahren Anwendung finden. Daher weisen modellprädiktive Regler gegenüber konventionellen Regelungen einen deutlich höheren Rechenzeitbedarf auf. Um der gegenwärtig begrenzten Rechenleistung von Steuergeräten im Automobilbereich gerecht zu werden, werden stark vereinfachte Modelle verwendet. Hierdurch und aufgrund der unzureichenden Prädiktion der Störgrößen, können die Regel- und Zustandsgrößen nur für einen verkürzten Prognosehorizont mit hinreichender Genauigkeit prognostiziert werden. Da durch eine modellprädiktive Regelung die Stellgrößen aber nur innerhalb des Prognosehorizonts optimiert werden, ist das gefundene Optimum lokal auf diesen verkürzten zeitlichen Horizont beschränkt. Hierdurch kann das gesamte Optimierungspotential nicht ausgeschöpft werden.

Ziel dieser Arbeit ist die Entwicklung eines modellprädiktiven Reglers zur Klimatisierung batterieelektrischer Fahrzeuge, der das vorhandene Optimierungspotential durch einen möglichst großen Prognosehorizont maximal ausschöpfen kann. Hierzu soll ein System mit präziser Vorhersage der thermischen Störgrößen, einem effizienten Modell des Innenklimas und ein effizientes Optimierungsverfahren entwickelt werden. Für diesen Zweck werden Methoden des maschinellen Lernens und metaheuristischen Optimierungsverfahren zu einem modellprädiktiven Regelungssystem verknüpft. Zur Prädiktion der thermischen Störgrößen werden Wetterdaten und -vorhersagen verschiedener Online-Dienste und Fahrzeugmessdaten verwendet.

1.2 Stand der Technik

In verschiedenen vorangegangenen Untersuchungen wurde das Potential modellprädiktiver Regelungen im Automobilbereich [7]-[9] als auch im Bereich des Fahrzeugwärmemanagements aufgezeigt [10]-[18]. In [8] werden verschiedene Anwendungen für modellprädiktive Regler im Automobilbereich mit vereinfachten linearen Modellen dargestellt, wobei der Schwerpunkt auf dem Gütefunktional für die verschiedene Anwendungen liegt. In [9] wird eine prädiktive Antriebsregelung zum energieoptimalen Betrieb von Hybridfahrzeugen vorgestellt. Durch dynamische Programmierung nach Bellmann wird unter Berücksichtigung einer Prädiktion der Störgröße Geschwindigkeit, eine optimale Trajektorie der Gangwahl sowie eine optimale Aufteilung des Fahrerwunschkomentes auf Motor, integrierten Startergenerator und Bremse berechnet. Das System wird durch ein nichtlineares Differentialgleichungssystem erster Ordnung beschrieben. Dieses Verfahren ist nicht problemlos auf Systeme höherer Ordnung übertragbar.

In [15] wird eine nichtlineare modellprädiktive Regelung (NMPC) vorgestellt, die die Fahrzeuginnentemperatur unter Minimierung des Energiebedarfs regelt. In [10] wird eine optimale Vorkondition-

ierung eines Elektrofahrzeugs bei teilweise bekanntem Lastprofil und eine Senkung des Fahrzeugenergiebedarfs durch Optimierung der Motor- und Batteriesolltemperatur bei unbekanntem Lastprofil vorgestellt. Hier wurde ein stark vereinfachtes Fahrzeugmodell in Kombination mit einem Downhill-Simplex-Optimierungsalgorithmus mit einem Vorrorschauhorizont von 500 Sekunden verwendet. In [13] wird ein NMPC verwendet, um gleichzeitig die Batterietemperatur und die Fahrzeuginnentemperatur zu steuern. In [16] wird ein NMPC zur Regelung der Fahrzeuginnentemperatur unter Optimierung der Batterielebensdauer SOH (State of Health) vorgestellt. Hierbei wurde im Vergleich zu einem konventionellen Zweipunktregler sowie zu einer Fuzzy-Regelung eine teilweise erhebliche Energiebedarfsreduzierung bis zu 67 % bei parallel verbessertem SoH anhand Simulationsergebnissen aufgezeigt. All diese Verfahren basieren auf einem stark vereinfachten nichtlinearen Differentialgleichungsmodell und einer Optimierung des Gütefunktional durch Sequential-Quadratic-Programming (SQP). Aufgrund der Modellvereinfachungen und Nichtberücksichtigung der Störgrößen, liefern diese Verfahren eine ausreichende Prädiktionsgüte für nur wenige Iterationsschritte und sind daher nur mit einem stark eingeschränkten Prognosehorizont anwendbar.

Die Verwendung von Wettervorhersagen für regelungstechnische Anwendung im Besonderen in Kombination mit modellprädiktiven Reglern wurde bereits in mehreren wissenschaftlichen Arbeiten untersucht [19]-[25]. Das Hauptanwendungsgebiet lag dabei in der Klimatisierung von Gebäuden. In [21] wurden die Auswirkungen der Vorhersagegenauigkeit verschiedener Vorhersagemodelle auf die Güte einer modellprädiktiven Regelung für der Klimatisierung von Gebäuden untersucht. Hierbei wurden verschiedene Verfahren auf der Basis von historischen Daten (TMY2-, Same-as-Yesterday- und Bin-Prädiktor) mit Verfahren basierend auf Unbiased Random Walk und auf Seasonal Autoregressive and Moving Average (SARIMA) verglichen. Es wurde festgestellt, dass hierbei die Bin-Modelle mit 7 Tagen und 30 Tagen die anderen Modelle weit an Vorhersagegenauigkeit übertreffen. Des Weiteren wurde festgestellt, dass im Vergleich zur modellprädiktiven Regelung mit perfekter Vorhersage, die Güte der Verfahren mit Bin-Prädiktor nur minimal schlechter waren. In [24] wurde ein verbessertes Prognoseverfahren zur Störgrößenvorhersage als auch Stochastische MPCs (SMPC) als eine Erweiterung von MPCs verwendet. Stochastische MPCs berücksichtigen Unsicherheiten des Messsystems, des Gesamtsystems und des Zustandsschätzers. Einen Überblick über SMPC findet sich in [26]. Zur Vorhersage des Wetters wurden Ergebnisse des numerischen Wettervorhersagemodells COSMO-7, lokal gemessenes Wetter des Wetterdienstes SWISS Meteorological Network sowie Gebäudemessungen verwendet. Hierfür wurde zusätzlich ein lineares Fehlermodell erstellt. Über einen Kalmanfilter wurden dann aus den verschiedenen Inputs die Vorhersagen erstellt. In [27] werden verschiedene MPC in Kombination mit interner naiver und Same-as-Yesterday-Prognose und externer Wetterprognose des MeteoSchweiz-Dienstes zur Regelung einer Wärmepumpenanlage für ein Gebäude untersucht. Bei den zugrundeliegenden Modellen handelt es sich hierbei um sehr stark vereinfachte lineare und nichtlineare Modelle.

In [23] wird die Verwendung von Online Wettervorhersagen diskutiert. Zur Temperaturvorhersage werden hierbei die vorhergesagten Temperaturen verschiedener online frei zugänglicher Wetterdienste zu einer verbesserten Vorhersage kombiniert. Des Weiteren wird die Vorhersage der Sonnenstrahlung, welcher nicht Bestandteil der Wettervorhersagen ist, diskutiert. Hierbei wird ein Verfahren vorgeschlagen, dass die theoretische Globalstrahlung in Abhängigkeit von Ort und Zeit für einen klaren Himmel als auch eine Verminderung der Bestrahlung durch die vorhergesagte Bewölkung berechnet. Durch ein lineares Regressionsmodell werden dann diese Prognosedaten mit tatsächlichen Messdaten in Verbindung gesetzt. Zusammenfassend kann gesagt werden, dass die gewonnen Erkenntnisse einen

großen Fortschritt für die Anwendung auf Regelung der Gebäudeklimatisierung bieten, sich aber nur bedingt auf das Gebiet der Regelung der Klimatisierung von Elektrofahrzeugen übertragen lassen. Durch die Größe, Bauform, thermische Speicherkapazität und Isolation reagiert das Gesamtsystem viel träger auf Änderungen äußerer Störgrößen. Hierdurch wirken sich kurzzeitige Schwankungen nicht so stark auf das Gesamtsystem aus. Des Weiteren wird das System in der Regel kontinuierlich und nicht wie beim Fahrzeug nur wenige Minuten bis Stunden betrieben. Hierdurch ist eine eher langfristige Prognose erforderlich, welche im Sinne der Verteilung des Prognosefehlers eine breitere Standardabweichung toleriert. Weiterhin dreht sich das Gebäude nicht und ändert auch nicht seine Position. Hierdurch verändern sich die zugehörigen Wetterbeobachtungsstationen und auch der Abstand zu diesen nicht, was in einer unterschiedlichen Vorhersagegüte resultiert. Die relative Position zur Sonne hängt lediglich von astronomischen Gesetzmäßigkeiten ab. Dies wiederum beeinflusst aber zum einen die maximal mögliche globale Sonnenstrahlung als auch die Seite des Systems, die zur Sonne gewandt ist. Ebenso verändert sich nicht die relative Position zu schattengebenden Nachbargebäuden, Pflanzen- und Baumbewuchs. Zusätzlich ist ein bewegendes Objekt offensichtlich größeren Wetterschwankungen ausgesetzt, da das Wetter von Ort zu Ort differierend sein kann. All dies erfordert eine aufwendigere Prognosetechnik.

Zur Prognose von Störgrößen in Fahrzeugen erfolgten Arbeiten, die Car-2-X Technologie verwenden und so externe Informationen weiterverarbeiten. In [28] wird ein System vorgestellt, das online-Wetterdaten für eine bevorstehende Fahrt zur Reichweitenvorhersage von Elektrofahrzeugen verwendet. In [29] werden Kartendaten der Fahrzeugnavigation verwendet, um eine energieoptimale Route unter Berücksichtigung der Klimatisierungsleistung zu berechnen. In [30] wird ein lernendes Verfahren vorgeschlagen, um die Straßeninfrastruktur zu lernen und vorherzusagen.

Eine Reihe von Untersuchungen beschäftigen sich mit einer detaillierten physikalischen Modellierung des Kabinenklimas von Fahrzeugen zu Simulationszwecken [31]-[43]. Neben der Innentemperatur, Luftfeuchte und Luftgüte werden hierbei z.T. ebenfalls thermischer Komfort in Form eines Predicted Mean Vote (PMV) berechnet. Mit den beschriebenen Modellierungsverfahren konnte eine hohe Vorhersagegenauigkeit im Sinne der Übereinstimmung von Mess- und Simulationsergebnissen erreicht werden. Diese Modelle sind z.T. nur mit erheblichem Aufwand auf andere Fahrzeugtypen übertragbar. Aufgrund der hohen Laufzeit sind diese aber nicht für den Einsatz in einem modellprädiktiven Regler geeignet. Zur Bewertung des in dieser Arbeit entwickelten Modells dienen sie aber zum einen als Vergleichsmaßstab, sowie als Grundlage des Simulationsmodells zum Test des entwickelten Reglers.

Einen Kompromiss zwischen Laufzeit und Vorhersagegenauigkeit bieten adaptiv lernende Verfahren mit Modellierung der Regelstrecke durch künstlich neuronale Netze. In [44] wird ein KNN zur Vorhersage der Fahrzeuginnentemperatur vorgestellt. Die Trainingsdaten basieren hierbei auf einer Simulation mit dem Simulationswerkzeug THESEUS-FE. In [45] und [46] werden nichtlineare autoregressive Neuronale Netze mit externen Eingängen (NARX) zur Vorhersage von Luftfeuchte und Raumtemperatur in Gebäuden vorgestellt. In [47] wird ein NARX in einem NMPC verwendet. Die Optimierung erfolgt nach Linearisierung der Zustandsgrößen durch ein Branch-and-Bound-Verfahren. Hierbei wird lediglich die Solltemperatur als Stellgröße verwendet. In [48] wird eine adaptive Regelung eines hydraulischen Vorschubzylinders durch Modellierung des nichtlinearen Verhaltens durch ein KNN vorgestellt. In [49] werden ebenfalls die Nichtlinearitäten innerhalb eines Beobachters durch KNN approximiert und so nichtmessbare Zustandsgrößen geschätzt. Die Regelung erfolgt im Zustandsraum durch Linearisierung um die Referenztrajektorie unter Verwendung einer quadratischen Programmierung zur Lösung des Optimierungsproblems mit Randbedingungen. Die Anwendung wird am Beispiel einer Fertigungs-

anlage und eines Radioteleskops gezeigt. Da die Nichtlinearität der Regelstrecke und der Störgrößen im Falle eines Fahrzeugs wie oben dargestellt, wesentlich komplexer ist, ist die Optimierung durch Linearisierung des Modells nicht ohne wesentliche Einbußen der Prädiktionsgenauigkeit möglich. Daher sind die Verfahren der Gebäudeklimatisierung nicht ohne weiteres auf ein Fahrzeug zu übertragen.

1.3 Forschungsfrage

Um den Schwächen der vorgestellten Ansätze zu begegnen, wird ein Lösungskonzept für eine modellprädiktive Regelung zur Innenraumklimatisierung batterieelektrischer Fahrzeuge auf Basis maschinellen Lernens entwickelt. Dieses Lösungskonzept wird im Vergleich zu einer konventionellen Regelung der Klimatisierung eines Elektrofahrzeugs beurteilt. Es soll dabei untersucht werden, inwieweit durch das entwickelte Lösungskonzept:

- die Maximierung der Regelgüte bei paralleler Minimierung des Energiebedarfs
- die Maximierung der Regelgüte bei begrenztem Energiebudget

im Vergleich zu einer konventionellen Regelung möglich ist. Hierzu wird als Referenz und zur Simulation ein Simulationsmodell eines Elektrofahrzeugs der TLK-Thermo GmbH verwendet.

Zur Umsetzung des modellprädiktiven Ansatzes ist eine Prognose von Regel- und Zustandsgrößen erforderlich. Hierfür soll untersucht werden, wie ein effizientes adaptives Modell des Kabinenklimas eines BEV zur Vorhersage der Regel- und Zustandsgrößen, bei bekanntem Verlauf der Stell- und Störgrößen, auf Basis maschinellen Lernens realisiert werden kann.

Da im Anwendungsfall zukünftige Störgrößen nicht bekannt sind, aber als Eingangsgrößen zur Regel- und Zustandsgrößenprognose benötigt werden, müssen diese ebenfalls prognostiziert werden. Daher ist es erforderlich, die auf das System wirkenden thermischen Störgrößen im Sinne eines Bewertungssystems präzise in Ausmaß und Wirkrichtung für einen definierten Zeitraum vorherzusagen. Hierfür soll untersucht werden, welchen Einfluss die Präzision der Störgrößenprognose auf die Genauigkeit der Prognose der Regel- und Zustandsgrößen haben, um die erforderliche Präzision der Störgrößenprognose zu ermitteln. Des Weiteren soll untersucht werden, wie diese erforderliche Präzision durch ein Teilsystem zur Störgrößenprognose realisiert werden kann.

Eine weitere Herausforderung stellt der Entwurf eines geeigneten Optimierungsverfahrens zur Berechnung der optimalen Trajektorie der Stellgrößen unter der Berücksichtigung der Regelziele und Nebenbedingung für einen möglichst großen Prädiktionshorizont dar. Hierfür müssen zunächst Optimalitätskriterien untersucht und festgelegt werden. Des Weiteren soll untersucht werden, wie eine Lösung für die festgelegten Optimalitätskriterien nahe am globalen Optimum gefunden werden kann. Die Referenz hierzu liefert wiederum der konventionelle Regler des Fahrzeugmodells.

Abschließend soll untersucht werden, wie die Teilsysteme zu einem Gesamtsystem integriert werden können. Um die Wirksamkeit des Gesamtregelungsansatzes nachzuweisen, muss das Leistungsvermögen dieses Gesamtsystems im Vergleich zur konventionellen Regelung bewertet werden.

1.4 Aufbau der Arbeit

Der Aufbau der Arbeit ist in Abbildung 1 dargestellt. Im Kapitel 2 erfolgt die Einführung in die theoretischen Grundlagen dieser Arbeit. Hierbei wird zunächst, ausgehend von den Grundlagen der Modellbildung, der klassische physikalische Modellierungsansatz und die hierfür benötigten thermodynamischen Grundlagen dargestellt. Anschließend erfolgt die Beschreibung der experimentellen Modellbildung durch künstlich neuronale Netze. Im darauffolgenden Unterkapitel erfolgt die Beschreibung der Grundlagen der modellprädiktiven Regelung.

Im dritten Kapitel erfolgt eine detaillierte Beschreibung der Anwendungsdomäne. Es wird zunächst der Entwicklungsprozess für Regelfunktionen zur Fahrzeugklimatisierung im Gesamtfahrzeugkontext beschrieben. Anschließend werden Anforderungen, Aufbau, Funktionsweise und die Regelung von Fahrzeugklimaanlagen erläutert.

Darauf aufbauend erfolgt die Entwicklung eines Lösungskonzept für eine modellprädiktive Regelung auf Basis maschinellen Lernens. Das Vorgehen als auch die Gliederung der folgenden Kapitel orientiert sich dabei am Problemlösungszyklus der Entwicklungsmethodik für mechatronische Systeme gemäß VDI-Richtlinie 2206. So werden im Kapitel 4 die Modellbildung für einen modellbasierten Entwicklungsansatz, eine Situationsanalyse der bestehenden Regelung (Altsystem) und die Zielformulierung für eine modellprädiktive Regelung vorgestellt.

Im Kapitel 5 erfolgt, basierend auf einem einleitend vorgestelltem Grobkonzept, die Untersuchung zu Lösungsansätzen für die Teilsysteme des Gesamtsystems. Abschließend werden im Kapitel 5.6 die Teilsysteme in der Systemsynthese zu einem Gesamtsystem integriert.

Im Kapitel 6 werden die Ergebnisse der experimentellen Untersuchungen des Gesamtsystems im Vergleich zum bestehenden System vorgestellt. Abschließend erfolgt in Kapitel 7 die Zusammenfassung und Ausblick.

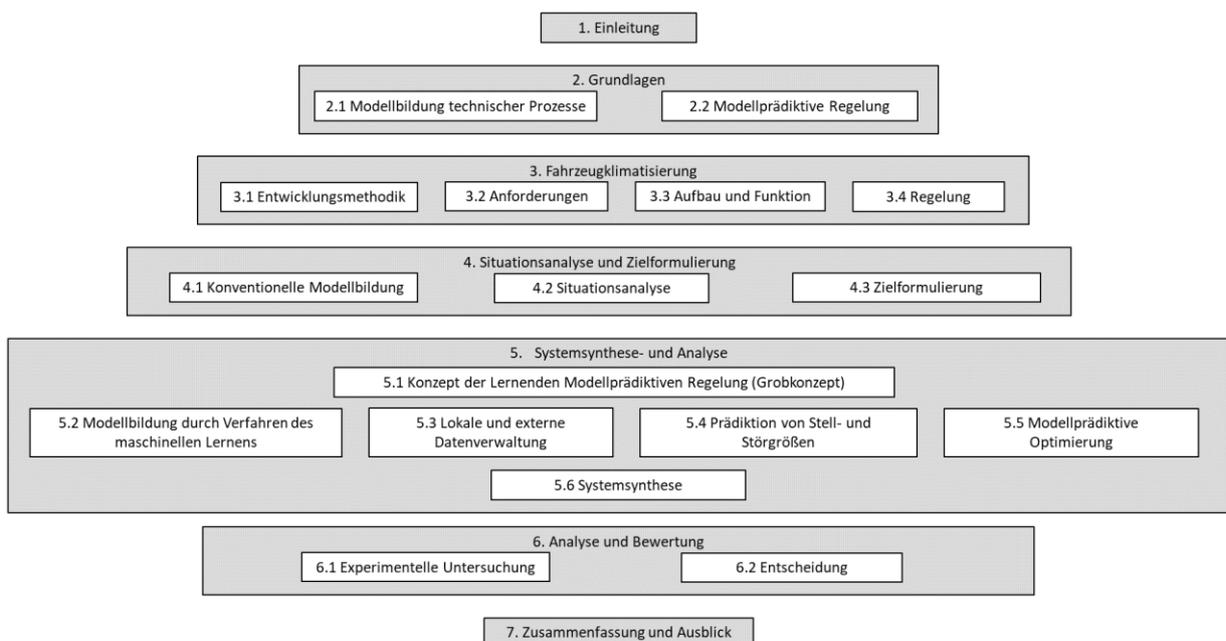


Abbildung 1 Aufbau der Arbeit

2 Grundlagen

2.1 Modellbildung technischer Prozesse

Die Entwicklung mathematischer Modelle technischer Prozesse stellt aus zwei Gründen ein wesentliches Element in der Entwicklung modellprädiktiver Regelung dar. Zum einen stellen mathematische Systemmodelle das zentrale Entwicklungswerkzeug im modellbasierten Entwicklungsprozess mechatronischer Systeme dar. Unabhängig vom Typ des zu entwerfenden Reglers, wird ein Modell der Regelstrecke benötigt, um einen Regler zu entwerfen und zu testen. Zum anderen sind mathematische Systemmodelle der Regelstrecke der zentrale Baustein aller modellprädiktiver Regelungen. Hierbei stellt das Modell selbst einen Teil des Reglers dar. Die beiden benötigten Modelle, das in der Entwicklungsumgebung und das im Regler eingesetzte, unterscheiden sich in ihrem Abstraktionsgrad bzgl. Laufzeit, Abbildungsgüte und Detaillierungsgrad. Dies ist in den unterschiedlichen Ressourcenbeschränkungen aufgrund der unterschiedlichen Zielhardware von Regler und Entwicklungsumgebung begründet. Da das Verständnis mathematischer Systemmodelle und ihrer Modellierung eine wesentliche Grundlage dieser Arbeit ist, werden im Folgenden die Grundbegriffe und Grundlagen der Modellbildung physikalischer Systeme erläutert. Eine detailliertere Beschreibung der Grundlagen der Modellbildung findet sich in [50], [51], [52] und [53], auf welchen die folgenden Unterkapitel basieren.

2.1.1 Grundlagen der Modellbildung

Ein Modell ist gem. VDI-Richtlinie 3633 die „vereinfachte Nachbildung eines geplanten oder existierenden Systems mit seinen Prozessen in einem anderen begrifflichen oder gegenständlichen System“ [54]. Ein System wird hierbei als eine „von ihrer Umwelt abgegrenzte Menge von Elementen, die miteinander in Beziehung stehen“ definiert. Jedes System² ist dabei durch seine

- Systemgrenze mit ihren Schnittstellen,
- die Subsysteme und Systemelemente,
- die Ablauf- und Aufbaustruktur der Elemente des Systems,
- durch Zustandsgrößen beschriebene Zustände der Elemente des Systems,
- die Zustandsübergänge mindestens einer Zustandsgröße aufgrund des in dem System ablaufenden Prozesses

gekennzeichnet. Ein Modell eines Systems „unterscheidet sich hinsichtlich der untersuchungsrelevanten Eigenschaften nur innerhalb eines vom Untersuchungsziel abhängigen Toleranzrahmens vom Vorbild. Ein Modell wird genutzt, um eine bestimmte Aufgabe zu lösen, deren Durchführung mittels direkter Operationen am Original nicht möglich oder zu aufwendig wäre.“ [54]

Mathematische Systemmodelle technischer Prozesse lassen sich nach der Vorgehensweise der Modellierung als auch durch eine Vielzahl von Modelleigenschaften beschreiben und unterscheiden. Die Wahl einer für den Modellierungszweck geeigneten Modellierungsvorgehensweise als auch der Modelleigenschaften hängt im Wesentlichen von den Eigenschaften des zu beschreibenden Systems und einer Reihe von Randbedingungen ab, weshalb diese in den folgenden Unterkapitel näher beschrieben werden.

² Hierbei wird, wie auch im Folgenden, der Systembegriff gem. DIN IEC 60050-351 verwendet.

2.1.1.1 *Vorgehensweise der Modellierung*

Gemäß [36] lassen sich mathematische Modelle nach der Vorgehensweise der Modellierung unterscheiden. Dabei wird zwischen theoretischer, experimenteller und hybrider Modellbildung unterschieden.

Durch die theoretische Modellbildung wird aus dem physikalischen Verhalten, wie z.B. aus den im folgenden Kapitel 2.1.3 vorgestellten thermodynamischen Beziehungen und Wechselwirkungen, ein mathematisches Modell abgeleitet. Hierzu müssen die physikalischen Gesetzmäßigkeiten vollständig erfasst werden und sämtliche Parameter des Systems wie z.B. Stoffkonstanten bekannt sein. Dieses Modell liegt dann in Form von linearen und nichtlinearen Differentialgleichungen und/oder algebraischen Gleichungen vor. Die durch diese Verfahren gewonnenen Modelle werden auch als White-Box-Modelle bezeichnet. Ein Vorteil dieses Ansatzes liegt, sofern die Gesetzmäßigkeiten vollständig erfasst und implementiert werden können, in der hohen Abbildungsgüte. Da jedoch bereits einfach erscheinende Komponenten, wie z.B. die Kältemittelleitung einer Klimaanlage, bereits ein komplexes Netzwerk thermischer Abhängigkeiten aufspannen, ist die physikalische Modellierung thermischer Systeme sehr anspruchsvoll und damit sehr zeitaufwendig. So kann es z.B. mehrere Personenmonate dauern, bis die Modellierung einer Pkw-Klimaanlage eines speziellen Typs modelliert und validiert ist. Ein weiterer Vorteil dieses Modellierungsansatzes ist die Übertragbarkeit des Modells auf ähnliche Systeme, sowie die Möglichkeit des Austauschs von Modellkomponenten aufgrund der Allgemeingültigkeit der physikalischen Gesetzmäßigkeiten. Je komplexer ein Modell wird, desto mehr Zeit kann die Simulation dieses Modells in Anspruch nehmen. Hier steht die Güte des Simulationsergebnisses in Konkurrenz zur Simulationsgeschwindigkeit. [55]

Bei der experimentellen Modellbildung können parametrische und nichtparametrische Verfahren, sowie Verhalten- und Strukturmodelle unterschieden werden. Werden ausgehend von einer a priori feststehenden Modellarchitektur nur die Parameter eines Modells angepasst, spricht man von einem parametrischen Verfahren. Strukturmodelle werden i.d.R. durch parametrische Verfahren gebildet. Ist die Modellstruktur a priori nicht festgelegt, sondern hängt von den Trainingsdaten ab, so spricht man von einem nichtparametrischen bzw. parameterfreien Verfahren.

Bleibt bei der Modellbildung die innere Struktur des abzubildenden Prozesses unberücksichtigt, spricht man von einem Verhaltensmodell. Verhaltensmodelle können sowohl durch parametrische als auch nichtparametrische Verfahren gewonnen werden. Diese Verfahren werden auch als Black-Box-Modellierungsverfahren bezeichnet. Die hierdurch erhaltenen Parameter sind in der Regel physikalisch nicht interpretierbar [56]. Liegt dem Entwurf der Modellarchitektur eine physikalische Struktur zu Grunde, weil z.B. durch eine theoretische Modellbildung die physikalischen Gesetzmäßigkeiten bereits erfasst wurden, aber die physikalischen Parameter des theoretischen Modells nicht vollständig bekannt sind, spricht man von einem Strukturmodell. Die hierdurch erhaltenen Parameter sind z. T. physikalisch interpretierbar. Ein typisches experimentelles parametrisches (Struktur-)Modellierungsverfahren der Regelungstechnik ist die Messung der Sprung- oder Impulsantwort einer Regelstrecke und Anpassung der Modellparameter einer standardisierten linearen zeitinvarianten Übertragungsfunktion (LZI-Übertragungsglied) bis die Kennlinien der Sprung- oder Impulsantwort übereinstimmen (vgl. hierzu [51]).

Verfahren des maschinellen Lernens, wie z.B. die Modellbildung durch künstlich neuronale Netze können ebenfalls als experimentelle (Verhaltens-)Modellierungsverfahren interpretiert werden. Der Vorteil dieser Verfahren ist, dass das physikalische Verhalten des abzubildenden Systems nicht bekannt

sein muss. Ein Nachteil dieser Ansätze ist die geringe Übertragbarkeit der gelernten Modelle auf ähnlich Systeme.

Durch eine hybride bzw. semi-empirische Modellbildung wird eine Mischform zwischen Black-Box- und White-Box-Modellen, sogenannte Grey-Box-Modelle, erstellt [36]. Grey-Box-Modelle werden i.d.R. zu den Verhaltensmodellen gezählt [56]. Diese Modelle bestehen sowohl aus theoretisch abgeleiteten und experimentell gewonnenen Modellkomponenten.

2.1.1.2 *Dynamische und statische Modelle*

Eine Möglichkeit zur Klassifizierung von Modellen stellt die Unterscheidung von statischen und dynamischen Modellen dar. Während statische Modelle Zustände eines Systems vor und nach äußeren Einwirkungen auf das System beschreiben, beschreiben dynamische Modelle die durch äußere Einwirkungen auf das System hervorgerufene Änderung von Zuständen des Systems. Dynamische Modelle beschreiben das zeitliche Verhalten von Größen des Systems. Dynamische Systeme können im Gegensatz zu statischen Systemen ein Gedächtnis besitzen. D.h. sie sind in der Lage Energie oder Informationen zu speichern und zeitverzögert abzugeben [56].

2.1.1.3 *Lineare und nichtlineare Modelle*

Ein Modell und ein System ist genau dann linear, wenn das Superpositionsprinzip für eine beliebige Kombination der Eingangsgrößen gilt [51]. Lineare kontinuierliche Systeme können immer durch lineare Differentialgleichungen und damit durch lineare Modelle beschrieben werden. Viele physikalischen Vorgänge in der Realität sind allerdings nichtlinearer Natur. Die Verwendung von nichtlinearen Modellen stellt aber, besonders im Hinblick auf ein später zu lösendes Optimierungsproblem, eine besondere Herausforderung dar. Deshalb wird oft versucht, bei auftretenden Nichtlinearitäten des zu beschreibenden Systems, diese zu linearisieren und damit das Systemverhalten dennoch hinreichend genau zu beschreiben. Ein verbreiteter Ansatz hierfür ist eine Taylor-Reihenentwicklung um einen Arbeitspunkt.

2.1.1.4 *Kontinuierliche und diskrete Modelle*

Dynamische Modelle können des Weiteren in kontinuierliche und diskrete Modelle unterschieden werden. Kontinuierliche Modelle beschreiben die Änderung von Systemzuständen durch Differentialgleichungen. Diskrete Modelle beschreiben die Änderung von Systemzuständen durch Differenzgleichungen. Messungen physikalischer Prozesse werden in der Regel diskret durchgeführt. Die Systemzustände zwischen den Messintervallen sind daher unbekannt. Wird ein Digitalrechner zur Regelung eines Prozesses eingesetzt, können auch nur zeitdiskrete Signale verarbeitet werden, weshalb eine diskrete Beschreibung des Systems erforderlich ist. [51]

2.1.1.5 *Zeitvariante und zeitinvariante Systeme*

Verändern sich Parameter eines Systems in Abhängigkeit der Zeit, so wird dieses System als zeitvariant bezeichnet. Ein Beispiel hierfür stellt die Änderung von Reflexions- und Absorptionskoeffizienten durch die Alterung von Lack und Material einer Fahrzeugkarosserie dar. Wird das zeitvariante Verhalten bei der physikalischen Modellierung berücksichtigt, kann dies eine erhebliche Komplexitätssteigerung des Modells zur Folge haben.

2.1.1.6 *Deterministisch und stochastische Modelle*

Ist das zeitliche Verhalten der Variablen eines Modells reproduzierbar, so werden diese Modelle in der Regelungstechnik als deterministisch bezeichnet. Weist mindestens eine Größe eines Modells ein regelloses Verhalten auf, so bezeichnet man dieses Modell als stochastisch. Die Werte der regellos

auftretenden Variablen können nur durch statistische Gesetzmäßigkeiten beschrieben werden [51]. Die Verwendung eines stochastischen Modells kann zur Beschreibung von nichtdeterministischen physikalischen Prozessen, wie z.B. Zerfallsprozesse radioaktiver Isotope oder nicht deterministisch beschreibbarer Prozesse, erfolgen.

2.1.1.7 *Kausale und akausale Modelle*

Wenn bei einem physikalischen Element eine Ursache als Folge eine bestimmte Wirkung hat, so bezeichnet man dies als eindeutige Kausalität. Betrachtet man die Eingangsgröße dieses Elements als Ursache, diese wird dann als eingeprägte Eingangsgröße bezeichnet, und die Ausgangsgröße als Wirkung, so kann die Ausgangsgröße als Funktion der Eingangsgröße dargestellt werden. Bei einem kausalen Element gilt dann die Umkehrung der Funktion nicht, da die Ursache nicht von der Wirkung abhängt. Gilt bei einem physikalischen Element auch die Umkehrung der Funktion, ist die eindeutige Kausalität nicht gegeben. [53]

Da die Zustände realer physikalischer Systeme nur von den aktuellen und vergangenen Zuständen des Systems selbst sowie äußerer Einwirkungen (eingeprägte Eingangsgrößen) abhängen, also das Ursache-Wirkungs-Prinzip gilt, bezeichnet man diese Systeme als kausal. Die Kausalität des Gesamtsystems wird aber erst durch das Zusammenschalten aller physikalischen Elemente des Systems mit den eingepägten Eingangsgrößen festgelegt [53]. Soll diese Kausalität durch ein mathematisches Modell direkt abgebildet werden, so ist dies nur über algebraische Gleichungen möglich. Hierbei spricht man von kausaler, blockbasierter oder auch signalflussorientierter Modellierung. Viele in der Literatur beschriebene Simulationsmodelle thermischer Systeme und Modell-Bibliotheken basieren auf signalflussorientierter Modellierungsweise. Auch bei der Beschreibung regelungstechnischer Systeme ist eine signalflussorientierte Beschreibung in Form von Blockschaltbildern üblich. Zur signalflussorientierten Modellierung sind zahlreiche ausgereifte Modellierungswerkzeuge, wie z.B. MATLAB/Simulink oder ETAS-ASCET verfügbar. Hierbei werden die Modelle durch signalflussorientierten Berechnungsblöcke direkt grafisch dargestellt und miteinander verbunden. Alternativ zu den meist proprietären Entwicklungswerkzeugen ist aber auch eine direkte Modellierung in Form von Funktionen oder Prozeduren durch Sprachen wie Java, C, C++ oder FORTRAN möglich. [57]

Die kausale Modellierung hat eine Reihe von Nachteilen. Die Abbildung vieler physikalischer Zusammenhänge, insbesondere nichtlinearer Systeme, durch eine kausale Modellierung ist sehr aufwendig, da Umformungen und Ableitungen aus Zustands- und Erhaltungsgleichungen notwendig sind. Bei komplexen Systemen stellt die Notwendigkeit konsistente Anfangsbedingungen herzustellen eine besondere Herausforderung dar. Des Weiteren werden kausale Modelle schnell sehr unübersichtlich und die Einsicht in die physikalische Struktur geht verloren [36]. Die Wiederverwendbarkeit kausaler Modelle ist zudem stark eingeschränkt.

Bei einer akausalen Modellierung erfolgt die Beschreibung des Systems und seiner Komponenten direkt durch die Zustands- und Erhaltungsgleichungen der physikalischen Gesetzmäßigkeiten in Form von algebraischen Gleichungen und Differenzialgleichungen. Man spricht hierbei von einer physikalischen, objekt-, potential- oder energiestromorientierten Beschreibung. Werkzeuge zur akausalen Modellierung werden auch als EOOT (equation based and object-oriented tools) bezeichnet [57]. Bei der akausalen Modellierung werden Potenzial- und Flussvariablen als Schnittstellenvariablen verwendet, deren Produkt typischerweise die Einheit der Leistung hat (z.B. Spannung und Strom). Die Komponenten werden hierarchisch aufgebaut und unabhängig von ihrer Umgebung definiert. Über die Potenzial- und Flussvariablen werden die Komponenten gerichtet oder ungerichtet miteinander verbunden.

Potenzial- und Flussvariablen können ebenfalls miteinander verbunden werden. Werden Potentialvariablen miteinander verbunden, so haben diese den gleichen Wert (z.B. Druck). Werden Flussvariablen miteinander verbunden, so ist deren Summe in einem Knoten stets 0. Die Kombination sämtlicher Komponenten- und Kopplungsgleichungen ergibt die vollständige Systembeschreibung in Form eines DAE-Systems (differential-algebraic equation system). Die Modellierung solcher Systeme erfolgt häufig rechnergestützt mit Modellierungswerkzeugen wie den MODELICA-basierten Modellierungstool Dymola oder MATLAB SIMSCAPE. Diese Werkzeuge sind i.d.R. neben der Modellierung in der Lage, die erstellten DAE-Systeme durch symbolische Transformation in eine für einen (im Werkzeug ebenfalls integrierten) numerischen Solver lösbare Form zu bringen [36]. Durch einen Solver kann dann das Gleichungssystem über numerische Verfahren gelöst und so Ausgangsgrößen des Modells berechnet werden.

Im Gegensatz zur kausalen Modellierung, bleibt bei der akausalen Modellierung die physikalische Struktur des Gesamtsystems erhalten, was u. a. zu einer besseren Übersichtlichkeit des Modells führt. Des Weiteren führt der komponentenbasierte Ansatz der akausalen Modellierung zu einer guten Wiederverwendbarkeit und Wartbarkeit der Modelle.

2.1.1.8 Modelle mit konzentrierten oder verteilten Parametern

Hängen Variablen eines dynamischen Modells nur von der Zeit und nicht vom Ort ab, so bezeichnet man dieses als Modell mit konzentrierten Parametern. Die physikalische Systembeschreibung dieser Modelle erfolgt mit gewöhnlichen Differentialgleichungen. Hängen Variablen eines dynamischen Modells von der Zeit und vom Ort ab, so bezeichnet man dieses als Modell mit verteilten Parametern. Die physikalische Systembeschreibung dieser Modelle erfolgt mit partiellen Differentialgleichungen. Modelle mit verteilten Parametern werden auch als Feldmodelle bezeichnet. Die partiellen Differentialgleichungen dieser Modelle werden i.d.R. approximativ mit numerischen Verfahren gelöst. Hierfür erfolgt eine Diskretisierung des Problems in endlich viele idealisierte Elemente entlang eines Rastergitters. Verbreitete Ansätze hierfür sind die Finite-Elemente-Methode (FEM), Finite-Volumen-Methode (FVM) und Finite-Differenzen-Methode (FDM).

Im Bereich der Modellierung des Fahrzeugkabinenklimas haben sich sowohl Modelle mit konzentrierten als auch Modelle mit verteilten Parametern etabliert. Zur Abbildung der Raumluftströmung werden z.B. die Modellierungsansätze der Ein-Zonen-, Mehr-Zonen- oder CFD-Modelle eingesetzt. Ein-Zonen-Modelle sind Modelle mit konzentrierten Parametern. Das gesamte Luftvolumen der Fahrzeugkabine wird hierbei als homogen angenommen. Bei Mehr-Zonen-Modellen wird das gesamte Luftvolumen der Fahrzeugkabine in kleinere homogene Luftvolumina diskretisiert. CFD-Modelle basieren auf Methoden der numerischen Strömungsmechanik (Computational Fluid Dynamics). Diese Modelle basieren je nach Detaillierungsgrad auf Navier-Stokes-, Euler- oder Potentialgleichungen welche mit den bereits erwähnten Lösungsansätzen, wie z.B. FEM, gelöst werden. CFD-Modelle sind i.d.R. sehr komplex und rechenaufwändig, erlauben dafür aber je nach Detaillierungsgrad mit einer sehr feiner Diskretisierung eine sehr hohe Abbildungsgenauigkeit. Aufgrund der hohen Komplexität werden in der Regelungstechnik Systeme mit verteilten Parametern häufig durch Modelle mit konzentrierten Parametern approximiert. Dies erfolgt auch in dieser Arbeit.

2.1.2 Klassische Modellbildung von Regelstrecken

Die Modellbildung von Regelstrecken als klassische Ingenieursdisziplin ist die Grundlage für den Reglerentwurf und damit für die Entwicklung von Regelfunktionen. Das Ziel der Modellbildung ist es, ein vorher definiertes physikalisches System, die darin ablaufenden technischen Prozesse und damit das wesentliche Streckenverhalten dieses Systems in Form eines mathematischen Modells abzubilden. Die Betrachtung des Systems erfolgt hierbei aus Sicht auf die im System ablaufenden mechanischen, elektrischen, hydraulischen, thermischen und thermodynamischen Prozesse [53]. Jeder hierbei betrachtete Prozess ist durch die Umformung und/oder den Transport von Materie, Energie und/oder Information gekennzeichnet [53].

Um ein physikalisches System zu beschreiben, ist es, wie einleitend bereits erwähnt, zunächst erforderlich, die Systemgrenze mit ihren Schnittstellen, die Subsysteme und Systemelemente sowie die Ablauf- und Aufbaustruktur der Elemente des Systems zu definieren. Die Systemgrenze beschreibt die Grenze des Systems gegenüber der Systemumwelt [52]. Das System tauscht über Schnittstellen an der Systemgrenze Energie, Materie und Informationen mit der Systemumwelt aus. Die festzulegende Systemgrenze kann identisch mit einer physikalischen Grenze des Systems (z.B. die Außenfläche der Fahrzeugkarosserie) sein, hängt aber in der Regel von der jeweiligen Fragestellung ab [52]. Die für den Modellierungszweck relevanten Beziehungen des Systems zur Systemumwelt werden über äußere Relationen (Ein- und Ausgangsgrößen) dargestellt. Da das System aus Prozesssicht betrachtet wird, handelt es sich hierbei um Energie-, Materie- und/oder Informationsströme.

Ist die Systemgrenze mit ihren Schnittstellen definiert, können die Systemelemente beschrieben werden. Systemelemente können wiederum Subsysteme oder elementare Bausteine des Systems sein. Die elementaren Bausteine von Systemen mit konzentrierten Parametern können in idealisierter Form in Quellen, Speicher, Übertrager, Wandler oder Senken unterschieden werden [53]. Diese elementaren Bausteine, welche auch als Prozesselemente bezeichnet werden, werden weiterhin, nach der Möglichkeit ihrer Steuerbarkeit durch eine Hilfsenergie, in passive und aktive Elemente unterschieden. In der Regelungstechnik werden die Eingangsgrößen von (Sub-)Systemen in unkontrollierbar auftretende (Störgrößen) und gezielt beeinflussbare Eingangsgrößen (Stellgrößen) unterschieden. Durch die stufenweise Aufgliederung des Gesamtsystems in Subsysteme und Systemelemente und deren Beziehungen untereinander entsteht eine hierarchische Struktur, deren Detaillierungsgrad von der Auflösungstiefe bzw. Stufe abhängig ist. Die Auflösungstiefe wiederum ist vom Modellierungszweck abhängig.

Ist die Struktur des Systems festgelegt, so müssen die Zustände der einzelnen Elemente des Systems durch Zustandsgrößen sowie die Zustandsübergänge mindestens einer Zustandsgröße aufgrund des in dem System ablaufenden Prozesses beschrieben werden [54]. Für Prozesse mit konzentrierten Parametern kann dies durch die sogenannten Grundgleichungen erfolgen. Die Grundgleichungen unterteilen sich nach [53] in:

- Bilanzgleichungen (Allgemeine Speicher, Verbindungsstellen),
- Konstitutive Gleichungen (Quellen, Übertrager, Wandler, spezielle Speicher),
- Phänomenologische Gleichungen (Senken).

Eine nähere Erläuterung der Grundgleichungen erfolgt am Beispiel der Modellierung des Fahrzeugklimas im folgenden Unterkapitel. Die Zustandsübergänge und ablaufenden Prozesse werden durch den Verlauf der Eingangs-, Ausgangs-, und Zustandsgrößen charakterisiert. Die Zustandsgrößen sind dabei

die Größen, die den Zustand von informations- oder energiespeichernden Elementen des (Sub-)Systems beschreiben (z.B. Wärmemenge im System). Aus der Kenntnis des Zustandes des Systems sowie der Eingangsgrößen zu einem bestimmten Zeitpunkt können die folgenden Zustände sowie die Ausgänge des Systems bestimmt werden. Da Gleichungen, die ein speicherndes Verhalten beschreiben, immer eine zeitliche Ableitung enthalten, kann jedes speichernde System über ein Integral bestimmt werden. Das hat zur Folge, dass Zustandsgrößen dann immer die Ausgangsgrößen von Integratoren sind [50].

Nach der Beschreibung der Prozesselemente durch die Grundgleichungen müssen sie entsprechend der festgelegten Struktur miteinander verschaltet werden. Eine Verbindungsstelle wird hierbei als Knoten, die Verbindungen zwischen zwei Knoten als Zweig bezeichnet. Man unterscheidet die beiden wesentlichen Grundschaltungsarten der Serien- und Parallelschaltung. Aufgrund der physikalischen Erhaltungssätze ergeben sich für Parallel- und Serienschaltungen die Kontinuitäts- bzw. Knotengleichungen (vgl. 1. Kirchhoffsches Gesetz) und die Kompatibilitäts- bzw. Umlaufgleichungen (vgl. 2. Kirchhoffsches Gesetz). Wie in 2.1.1.7 bereits erwähnt, werden für Flussvariablen Knotengleichungen und für Potentialvariablen Umlaufgleichungen aufgestellt.

Mit den erstellten Grund- und Kopplungsgleichungen kann dann ein Gleichungssystem für das Gesamtsystem erstellt werden, aus welchem die Zustandsdifferentialgleichungen für die Ein- und Ausgänge des Systems abgeleitet werden können [53]. Im Bereich der Regelungstechnik hat sich die sogenannte Zustandsraumdarstellung als mathematische Repräsentationsform physikalischer Modelle durchgesetzt [50]. Physikalische Modelle in Zustandsraumdarstellung können zum einen als Schnittstelle zur Simulation (Simulationsmodell) dienen [50] und zum anderen als Prozess- bzw. Prognosemodell innerhalb einer klassischen modellprädiktiven Regelung verwendet werden (vgl. hierzu Kapitel 2.2.1.). Im Gegensatz zu den Ingenieurwissenschaften wird in der Mathematik in der Regel nicht der Begriff der Zustandsraumdarstellung verwendet. Hier erfolgt die Beschreibung von physikalischen Systemen durch *Systeme gewöhnlicher Differentialgleichungen erster Ordnung* (ODE - ordinary differential equations). Werden diese (Gleichungs-)Systeme in kompakte Matrizendarstellung gebracht, so werden diese in den Ingenieurwissenschaften als Zustandsgleichungen bezeichnet. Werden die Zustandsgleichungen noch um eine sogenannte Ausgangsgleichung erweitert, so wird dies als Zustandsraumdarstellung bezeichnet.

2.1.3 Thermodynamische Grundlagen

Für die Regelung von PKW-Klimaanlagen und die theoretische physikalische Modellbildung sind die Grundlagen der Wärme- und Stoffübertragung von zentraler Bedeutung und werden in den folgenden Kapiteln daher näher erläutert. Eine detaillierte Beschreibung der Modellbildung des thermischen Verhaltens von Fahrzeugkabinen findet sich in [36], [37] und [43]. Eine ausführlichere Beschreibung der thermodynamischen Grundlagen erfolgt in [3], [5], [40], [43], [58] und [59], auf welchen die folgenden Unterkapitel inkl. deren Gleichungen basieren.

Aus thermodynamischer Sicht kann die Fahrzeugkabine als ein offenes thermodynamisches System betrachtet werden, da neben Wärme und Arbeit ebenfalls Masse über die Systemgrenze transportiert wird. Die zentralen Regelgrößen des Systems stellen, wie bereits beschrieben, die Temperatur und die relative Feuchte der Kabinenluft dar. Ein verbreiteter Ansatz zur Berechnung dieser Größen, ist die Bilanzierung der Wärme- und Enthalpieströme [40]. Aus diesem Grund werden in den folgenden Unterkapiteln diese Begriffe näher erläutert.

2.1.3.1 Wärmestrom und Wärmetransport

Die Energie eines Systems kann gemäß dem Energieerhaltungssatz nur dadurch geändert werden, dass Energie während eines Prozesses über die Systemgrenzen transportiert wird. Bei einem für Materie undurchlässigen System, also einem geschlossenen System, kann Energie nur durch den Transport von Wärme und als Arbeit über die Systemgrenzen transportiert werden. Bei einem offenen System kann Energie auch mit einem Materiestrom über die Systemgrenzen transportiert werden. Als Wärme Q bezeichnet man dementsprechend den Anteil der Energie, der zwischen zwei thermodynamischen Systemen allein aufgrund von Temperaturunterschieden über die Systemgrenzen transportiert wird. Die Wärme fließt hierbei stets vom System der höheren Temperatur zum System der niedrigeren Temperatur. Die über die Zeit δt über die Systemgrenze übertragene Wärmeenergie δQ bezeichnet man als Wärmestrom

$$\dot{Q} = \frac{\delta Q}{\delta t}. \quad (1)$$

Der (stoffgebundene) Wärmestrom zwischen zwei Systemen A und B ist proportional zur Differenz der Temperaturen T_A und T_B . Bei $T_A > T_B$ gilt

$$\dot{Q} = k \cdot A \cdot (T_A - T_B). \quad (2)$$

Hierbei ist A die Fläche der Systemgrenze und k der Wärmedurchgangskoeffizient. Der Wärmedurchgangskoeffizient wiederum hängt von mehreren Größen wie dem Wärmeübergangskoeffizienten α zwischen festem Körper und Fluid sowie der Wärmeleitfähigkeit λ und Geometrie des festen Körpers ab.

Die Wärme ist eine Prozessgröße und daher nicht zur Beschreibung des Zustandes eines Systems geeignet. Der thermische Zustand eines Systems kann durch die thermische Energie E_{th} und die Enthalpie H beschrieben werden. Die thermische Energie E_{th} ist näherungsweise proportional zur Temperatur des Systems. Durch eine Zufuhr von Wärme wird die Zustandsgröße thermische Energie E_{th} eines Systems erhöht, durch eine Abfuhr verringert. Die thermische Energie wird als Produkt der Wärmekapazität, Masse und Temperatur definiert:

$$E_{th} = c \cdot m \cdot T. \quad (3)$$

Die Übertragung von Wärme kann durch die Mechanismen Konvektion, Wärmeleitung und Wärmestrahlung erfolgen. Abbildung 2 zeigt vereinfacht die durch Konvektion, Wärmeleitung und Wärmestrahlung verursachten Wärmeströme an einem vereinfachten Modell einer Fahrzeugkabine. Diese Mechanismen werden in den folgenden Unterkapiteln näher erläutert.

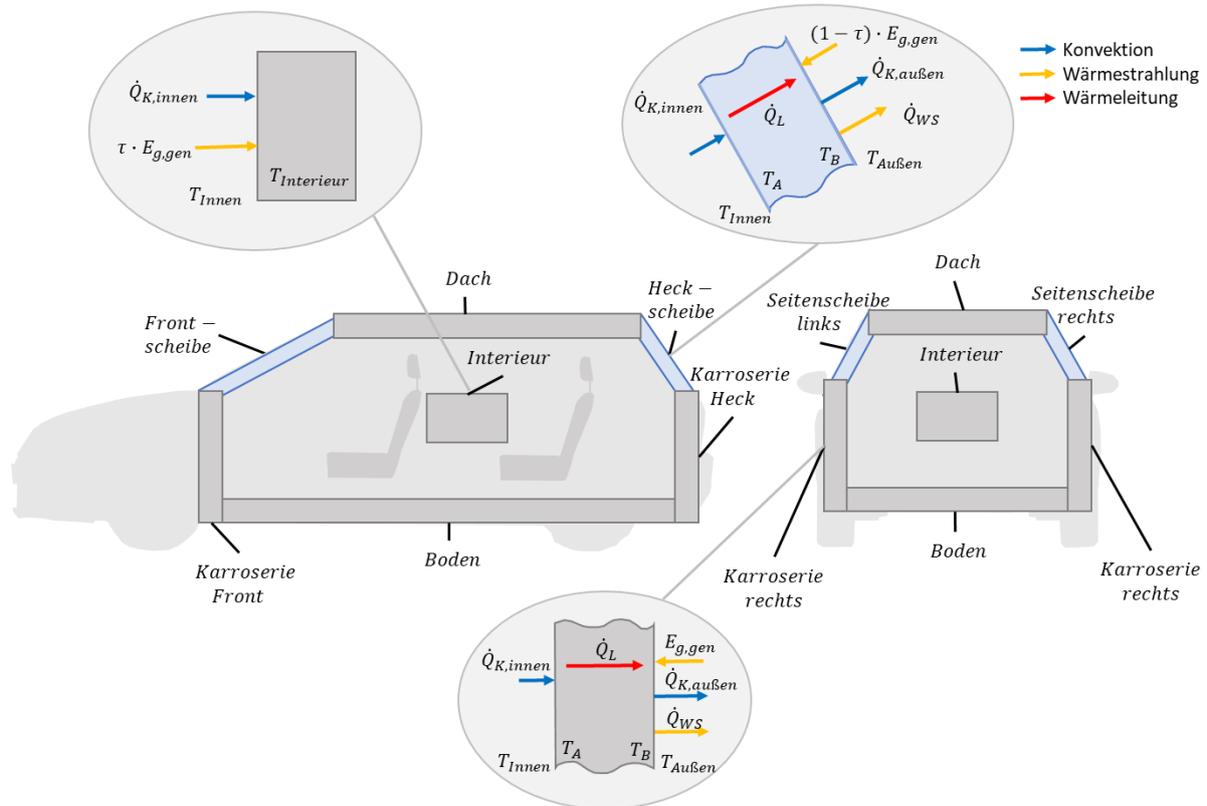


Abbildung 2 Wärmeströme an einer Fahrzeugkabine

2.1.3.1.1 Konvektion

Konvektion ist der Wärmestrom zwischen zwei Medien unterschiedlicher Temperatur, die sich relativ zueinander bewegen [59]. Hierbei handelt es sich in der Regel um ein Fluid, das einen Festkörper mit einer Temperaturdifferenz umströmt. Man unterscheidet nach der Strömungsursache erzwungene und freie Konvektion. Freie Konvektion, auch als natürliche Konvektion bezeichnet, wird durch Dichteunterschiede im Medium hervorgerufen. Liegt z.B. eine Wärmequelle unterhalb einer Wärmesenke, erfährt das Fluid im unteren Bereich einen statischen Auftrieb, da sich seine Dichte aufgrund der Erwärmung verringert. Im oberen Bereich wird durch die von der Wärmesenke verursachte Abkühlung eine Erhöhung der Dichte des Fluids bewirkt, wodurch eine Zirkulation verursacht wird. Erzwungene Konvektion wird im Gegensatz hierzu durch einen Druckunterschied verursacht. Dieser kann beispielsweise bei einem Fahrzeug im Innenraum durch die Lüfter und an den Außenflächen durch die Fahrzeugbewegung oder Wind verursacht werden. Eine analytische Bestimmung der Konvektion ist in der Regel nicht möglich, da hierfür das 3-dimensionale Geschwindigkeitsfeld der Strömung bekannt sein muss [40]. Daher wird der konvektive Wärmestrom oft, basiert auf der Ähnlichkeitstheorie, nach dem phänomenologischen Newtonschen Ansatz beschrieben:

$$\dot{Q}_K = \alpha \cdot A \cdot (T_A - T_B). \quad (4)$$

Hierbei sind T_A und T_B die Temperaturen des Fluids und der Oberfläche des Festkörpers, A die angeströmte Fläche und α der Wärmeübergangskoeffizient. Der Wärmeübergangskoeffizient wiederum

hängt von einer Reihe von Parametern wie der kinematischen Viskosität ν , der Wärmeleitfähigkeit λ , der Strömungsgeschwindigkeit sowie geometrischen Parametern wie Überströmlänge und Neigung der angeströmten Fläche ab. Zur Quantifizierung des Wärmeübergangskoeffizienten wird die dimensionslose Nusseltzahl verwendet:

$$\alpha = \frac{Nu \cdot \lambda}{L}. \quad (5)$$

Hierbei ist λ die Wärmeleitfähigkeit des Fluids und L die charakteristische Länge. Die Nusseltzahl und die charakteristische Länge müssen wiederum je nach Konvektionsart durch eine Reihe dimensionsloser Kennzahlen wie der Reynoldszahl, Prandtlzahl, Grashofzahl und Rayleighzahl sowie von Geometriefaktoren bestimmt werden. Eine ausführliche Beschreibung der Bestimmung dieser Kennzahlen für Fahrzeugflächen erfolgt in [43].

Zur Berechnung der Innenraumlufttemperatur im Fahrzeug über eine Bilanzierung der Wärme- und Enthalpieströme verläuft die thermodynamische Systemgrenze an den Innenflächen der Fahrzeugkabine. Die Übertragung von Wärme über diese Systemgrenze erfolgt über die Mechanismen der Strahlung und der Konvektion. Zur Quantifizierung der konvektiven Wärmeströme muss die Temperaturdifferenz zwischen der Innenraumluft T_{Innen} und der Umschließungsflächen T_A bekannt sein. Dies erfordert die Kenntnis der Oberflächentemperatur aller Bauteile der Umschließungsflächen, welche wiederum als separate thermodynamische Systeme beschrieben werden können. Die Oberflächentemperatur dieser Systeme kann wiederum über eine Bilanzierung der Wärmeströme erfolgen. Neben der Konvektion erfolgt die Wärmeübertragung in diesen Fällen ebenfalls über die Mechanismen Wärmeleitung und Strahlung. Abbildung 3 veranschaulicht die Wärmeströme an der Fahrzeugkabinenwand.

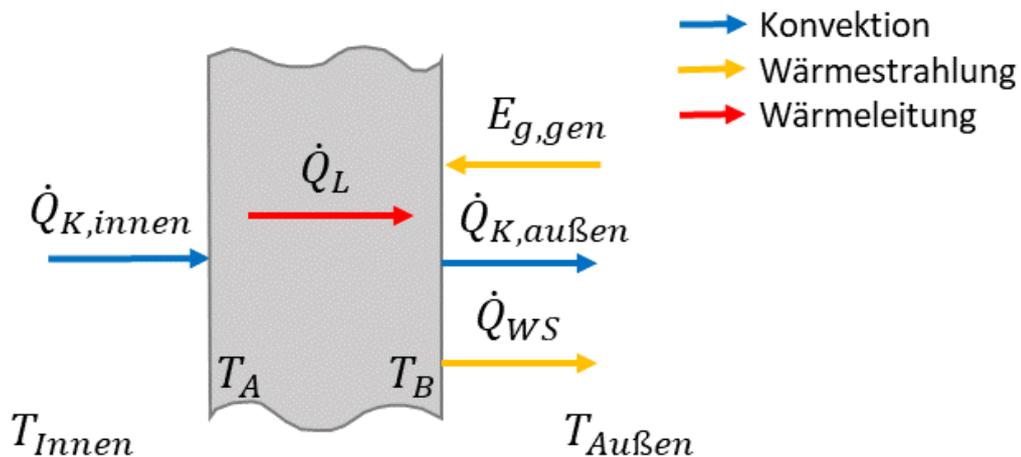


Abbildung 3 Wärmeströme an der Fahrzeugkabinenwand

2.1.3.1.2 Wärmeleitung

Wärmeleitung, oft auch als Konduktion oder Wärmediffusion bezeichnet, ist der Wärmestrom in einem Festkörper oder ruhendem Fluid. Während in Festkörpern allein die Wärmeleitung für den Energietransport verantwortlich ist, wird der Wärmetransport in Fluiden zusätzlich zur Wärmeleitung durch Konvektion überlagert [59]. Der Wärmestrom durch eine ebene Platte kann nach dem phänomenologischen Fourierschen Ansatz beschrieben werden:

$$\dot{Q}_L = \lambda \cdot A \cdot \frac{T_A - T_B}{d}. \quad (6)$$

Hierbei sind T_A und T_B die Temperaturen der gegenüberliegenden Plattenoberflächen, A die durchströmte Fläche, d die Dicke der Platte und λ die Wärmeleitfähigkeit. Bei der Betrachtung des Fahrzeugklimas kann mit dem Fourierschen Ansatz die Wärmeübertragung durch feste Bauteile wie durch die Scheiben oder die Karosserie beschrieben werden. Obwohl in der Realität sowohl komplexere Bauformen als auch unterschiedliche, in Reihe und parallel geschaltete Materialien auftreten, lassen sich mit diesem Ansatz gute Näherungen erzielen [40].

2.1.3.1.3 Strahlung

Im Gegensatz zur Wärmeleitung und Konvektion ist die Wärmestrahlung ein nicht stoffgebundener Wärmetransportmechanismus. Der Wärmetransport erfolgt durch elektromagnetische Wellen, welche von jedem festen Körper und Fluid mit einer Temperatur über dem absoluten Nullpunkt ausgesendet werden [40]. Der von einem Körper durch Wärmestrahlung emittierte Wärmestrom lässt sich mit dem Stefan-Boltzmann-Gesetz beschreiben:

$$\dot{Q}_E = \varepsilon \cdot \sigma \cdot A \cdot T^4. \quad (7)$$

Hierbei ist ε der Emissionsgrad, welcher die Strahlungsfähigkeit eines Körpers beschreibt. In der Thermodynamik unterscheidet man schwarze, weiße und graue Körper. Ideale schwarze Körper haben einen Emissionsgrad von 1, was ihre Eigenschaft beschreibt, ihre Wärmestrahlung mit einer maximalen Intensität auszusenden. Reale Körper können diese maximale Intensität nicht erreichen. Der Emissionsgrad dieser Körper wird durch das Verhältnis ihrer Strahlungsintensität zur theoretischen Strahlungsintensität eines schwarzen Körpers bei gleicher Temperatur berechnet [43]. Weiterhin stellt A die Fläche des Körpers und σ die Stefan-Boltzmann-Konstante mit

$$\sigma = 5,67 \cdot 10^{-8} \frac{W}{m^2 K^4} \quad (8)$$

dar. Um den Wärmestrom zwischen zwei Körpern zu berechnen, ist ebenfalls der Absorptionsgrad α des bestrahlten Körpers, der gemäß dem Kirchhoffschen Gesetz dem Emissionsgrad ε entspricht, zu berücksichtigen. Der Wärmestrom zwischen zwei Körpern A und B aufgrund von Wärmestrahlung ergibt sich zu:

$$\dot{Q}_{AB} = \varepsilon_A \cdot \varepsilon_B \cdot \sigma \cdot A_{AB} \cdot (T_A^4 - T_B^4). \quad (9)$$

Da aufgrund der räumlichen Orientierung der Körper nur ein Teil der emittierten Strahlung eines Körpers auf nur einen Teil der Fläche des bestrahlten Körpers trifft, ist dies in der Strahlungsaustauschfläche A_{AB} zu berücksichtigen. In einer Fahrzeugkabine tritt neben der Wärmestrahlung zwischen allen Fahrzeugbauteilen auch ein Strahlungsaustausch zwischen dem Interieur und den Insassen auf. Um diesen zu quantifizieren, werden Ansatzfunktionen für die Oberflächentemperatur der Insassen verwendet [43]. Neben dem Strahlungsaustausch innerhalb der Fahrzeugkabine tritt ebenfalls ein Wärmestrom durch Strahlungsaustausch zwischen der Umgebung und dem Fahrzeug auf. Hierbei sind vor allem der Strahlungsaustausch des Fahrzeugs mit dem Himmel, der Straße und der Sonne zu beachten. Um die Wärmeströme durch Strahlungsaustausch des Fahrzeugs mit dem Himmel und der Straße zu quantifizieren, werden Ansatzfunktionen für die Temperatur des Himmels und der Straße verwendet (vgl. [43], [60] und [61]). Neben dieser langwelligen Wärmestrahlung trifft ebenfalls lang- und kurzwellige Sonnenstrahlung auf Karosserie und Scheiben. Da heutige Fahrzeugscheiben in der Regel annähernd undurchlässig für langwellige Strahlung sind, gelangt hiervon ein kurzwelliger Anteil durch die Scheiben in den Innenraum und wird zu einem großen Teil von den Interieurflächen absorbiert. Da die

von den Interieurflächen im Innenraum emittierte Wärmestrahlung wiederum langwellig ist, kann diese die Scheiben nicht nach außen passieren, was zum sogenannten Treib- bzw. Glashauseffekt führt. Der Energieeintrag auf ein Fahrzeug durch solare Strahlung ist im Wesentlichen abhängig von der relativ konstanten Strahlungsleistung der Sonne, vom Winkel der Sonneneinstrahlung, dem Ausmaß an atmosphärischer Reflexion und Absorption, der Bewölkung und der Position von schattengebenden Objekten. Die Sonnenstrahlung setzt sich hierbei aus direkter und indirekter Strahlung zusammen. Diffuse Strahlung entsteht durch Streuung und Reflektion der Sonnenstrahlung an Staub- und Luftmolekülen in der Erdatmosphäre. Die diffuse Strahlung wirkt aus allen Richtungen auf das Fahrzeug und ist auch bei starker Bewölkung und im Schatten vorhanden [43]. Untersuchungen auf den Gebieten der Agrarmeteorologie und regenerativer Energiesysteme zeigen, dass der Anteil der direkten Strahlung sehr gut berechnet werden kann, wenn die Position der Sonne relativ zum Standort bekannt ist (vgl. [60] und [62]). Die nachfolgenden Gleichungen fassen die Berechnung gemäß [43], [60], [62] und [63] zusammen. Der Energieeintrag durch solare Strahlung auf eine horizontale Fläche wird mit der Gesamtbestrahlungsstärke $E_{G,hor}$ beschrieben:

$$E_{g,hor} = E_0 \cdot \tau_A \cdot \tau_B \cdot \sin \gamma_S. \quad (10)$$

Hierbei ist E_0 die Solarkonstante. Sie beschreibt die mittlere extraterrestrische Bestrahlungsstärke der Sonne zur Erde [60]. Da die Entfernung von Sonne und Erde im Laufe des Jahres schwankt, schwankt auch die extraterrestrische Bestrahlungsstärke E_e zwischen 1315 W/m^2 und 1406 W/m^2 , der Mittelwert beträgt

$$E_0 = 1360,8 \pm 0,5 \frac{\text{W}}{\text{m}^2}. \quad (11)$$

Die extraterrestrische Strahlung wird auf dem Weg durch die Erdatmosphäre durch Reflexion und Absorption an der Atmosphäre sowie durch Rayleigh- und Mies-Streuung reduziert. Diese Reduktion wird durch den Transmissionsgrad der Atmosphäre τ_A [60] oder alternativ durch den Trübungsfaktor nach Linke [64] berücksichtigt. Der Transmissionsgrad τ_B beschreibt die Reduktion der Strahlung aufgrund der Bewölkung. Die Reduktion der Sonnenstrahlung korrespondiert weiterhin mit der Länge des Weges der Sonnenstrahlung durch die Erdatmosphäre. Diese ist abhängig von der Sonnenhöhe γ_S . Bei einer Sonnenhöhe von 90° werden daher maximale Strahlungswerte erreicht. Allerdings tritt dieser Winkel nur zwischen dem nördlichen und südlichen Wendekreis der Erde zweimal pro Jahr auf. In Deutschland erreicht die Sonnenhöhe einen Tageshöchststand zwischen $63,45^\circ$ zur Sommersonnenwende und $16,55^\circ$ zur Wintersonnenwende. Der Sonnenwinkel kann in Abhängigkeit der Sonnendeklination δ , des Stundenwinkels ω und der geografischen Breite des Standorts φ_B mit

$$\gamma_S = \arcsin(\cos(\omega) \cdot \cos(\varphi_B) \cdot \cos(\delta) \cdot \sin(\varphi_B) \cdot \sin(\delta)) \quad (12)$$

berechnet werden. Der hierin enthaltene Stundenwinkel berechnet sich zu:

$$\omega = (12:00 \text{ h} - WOZ) \cdot \frac{15^\circ}{\text{h}}. \quad (13)$$

Hierin ist WOZ die wahre Ortszeit. Die Sonne steht an einem Standort zur WOZ von 12:00 Uhr exakt im Süden.

Die wahre Ortszeit kann aus der mitteleuropäischen Uhrzeit MEZ , der Zeitgleichung ZGL und der geographischen Länge φ_L berechnet werden:

$$WOZ = MEZ - 4 \cdot (15^\circ - \varphi_L) \cdot \frac{\text{min}}{\circ} + ZGL. \quad (14)$$

Über den geographischen Längengrad wird hierbei die Differenz der lokalen mittleren Ortszeit MOZ zur mittleren Ortszeit MOZ am fünfzehnten Längengrad, auf welchem z.B. die Stadt Görlitz liegt, berechnet. Hierbei werden für jeden Längengrad Abweichung jeweils vier Minuten abgezogen. Die Zeitgleichung

$$ZGL = 0,3948 - 23,2559 \cdot \cos(J' + 85,9^\circ) + 9,9359 \cdot \cos(2 \cdot J' + 108,9^\circ) + 0,3387 \cdot \cos(3 \cdot J' + 105,2^\circ) \cdot \text{min} \quad (15)$$

berücksichtigt die jahreszeitabhängigen Schwankungen zwischen mittlerer und wahrer Ortszeit, welche durch die elliptische Bahn der Erde um die Sonne verursacht wird. Hierbei beschreibt J' die aktuelle Jahreszeit mit:

$$J' = 360^\circ \cdot \frac{\text{laufender Tag des Jahres}}{\text{Anzahl der Tage im Jahr}}. \quad (16)$$

Abbildung 4 zeigt einen Vergleich der nach (10) bis (16) berechneten Bestrahlungsstärke mit der tatsächlich gemessenen Bestrahlungsstärke³ für den Standort Clausthal vom 06.04.2018 bis zum 10.04.2018.

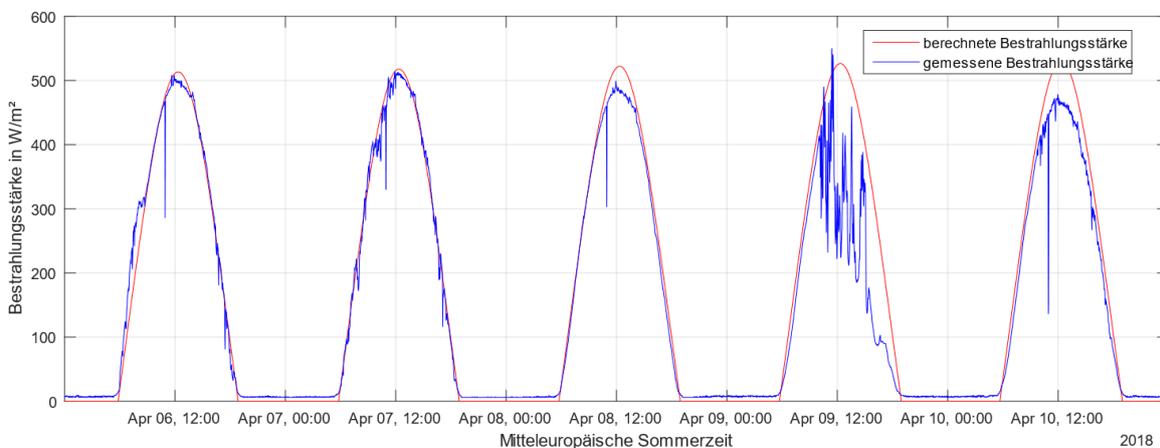


Abbildung 4 Vergleich der gemessenen und berechneten solaren Bestrahlungsintensität

Hierbei ist zu erkennen, dass nur der direkte Anteil der solaren Strahlung berechnet werden kann. Tritt durch vorhandene Bewölkung diffuse Strahlung, wie z.B. am 09.04.2018 auf, ist eine Vorhersage der Gesamtstrahlung durch diese Verfahren nicht möglich. Bei stark wechselnder Bewölkung können durch zusätzliche Reflexionen an den Wolken Bestrahlungsstärkewerte oberhalb der Solarkonstante auftreten [60]. In [63] wird ein Verfahren zur Berechnung der Beleuchtungsverhältnisse bei

³ Die Messwerte entstammen der Messanlage auf dem Dach des Instituts für elektrische Informationstechnik der TU Clausthal.

idealisiertem klarem, mittlerem und bedecktem Himmel beschrieben, die auf langfristigen mehrjährigen Mittelwerten beruhen.

Da solare Strahlung überwiegend in einem geneigten Winkel auf die Oberflächen des Fahrzeugs trifft, ist analog zu (7) die bestrahlte Fläche der einzelnen Bauteile in Abhängigkeit der Winkel der Normalenvektoren der Flächen zum Einfallswinkel der Sonnenstrahlung zu berücksichtigen. Der resultierende gesamte Wärmestrom $E_{g,gen}$ auf die geneigten Oberflächen der bestrahlten Bauteile ist analog zu (7) ebenfalls abhängig vom Absorptions- bzw. Emissionsgrad der Bauteile. Diese sind im Fall der Karosserieteile im Wesentlichen von der Lackierung der Bleche abhängig. In [5] wird der Einfluss der Farben auf die Aufheizung lackierter Bleche in der Sonne näher erläutert. Neben der solaren Wärmestrahlung auf die äußeren Bauteile des Fahrzeugs tritt ebenfalls Wärmestrahlung durch die Scheiben auf Bauteile im Fahrgastraum. Die Strahlungsdurchlässigkeit der Scheiben wird durch ihren Transmissionsgrad τ_S beschrieben. Der Transmissionsgrad der Scheiben ist wiederum abhängig vom Einfallswinkel der Strahlung und von den Materialeigenschaften der Gläser. Um diese zu quantifizieren werden in der Regel Messungen der Transmission im Labor von Glaslieferanten durchgeführt [5].

2.1.3.2 Enthalpieströme

Enthalpie ist eine abstrakte extensive Zustandsgröße zur Beschreibung der Energie thermodynamischer Systeme, die aus der Summe der inneren Energie eines Systems und dem Produkt aus Druck p und Volumen V gebildet wird:

$$H = U + p \cdot V. \quad (17)$$

Durch die Verwendung der Enthalpie lässt sich die einem System mit einem Massestrom zugeführte Energie quantifizieren. Im Falle der Fahrzeugkabine sind dies der Enthalpiestrom der Zuluft aus Klimatisierung und Heizung \dot{H}_{Zuluft} , der durch Leckagestrom und Abluftöffnungen entweichende Enthalpieströme \dot{H}_{Abluft} und der durch Atmung und Wärme der Insassen verursachte Enthalpiestrom $\dot{H}_{Insassen}$. Über eine Energiebilanz, unter zusätzlicher Berücksichtigung der konvektiven Wärmeströme \dot{Q}_K , lässt sich bei Vernachlässigung der potentiellen und kinetischen Energie sowie der thermischen Ausdehnung des Luftvolumens die Änderung der inneren Energie der Kabinenluft berechnen (vgl. [3] und [40]):

$$\frac{dU}{dt} = - \sum \dot{Q}_K + \dot{H}_{Zuluft} + \dot{H}_{Abluft} + \dot{H}_{Insassen}. \quad (18)$$

Die Enthalpieströme sind im Wesentlichen abhängig von den Masseströmen \dot{m} der zu- bzw. abgeführten Luft, deren Temperaturen T und Wasserbeladungen x . Hieraus ergibt sich

$$\dot{H} = \dot{m} \cdot T \cdot (c_L + x \cdot c_D) + \Delta h_v. \quad (19)$$

Die Verdampfungsenthalpie Δh_v ist die benötigte Energie des Aggregatzustandswechsels der im Luftstrom mitgeführten Wassermenge. Die innere Energie der Kabinenluft im Fahrzeug ergibt sich aus der Summe der inneren Energie der trockenen Luft U_L und der inneren Energie des in der Luft vorhandenen Wasserdampfes U_D :

$$U = U_L + U_D. \quad (20)$$

Die innere Energie der trockenen Luft U_L berechnet sich aus der spezifischen Wärmekapazität c_L , der Masse m_L , der Temperatur T , des Partialdrucks p_L und des spezifischen Volumens v_L der trockenen Luft mit

$$U_L = m_L \cdot (T \cdot c_L - p_L \cdot v_L). \quad (21)$$

Die innere Energie des Wasserdampfes berechnet sich, ausgenommen der zusätzlichen Berücksichtigung der Verdampfungsenthalpie Δh_v , analog zu (21) aus

$$U_D = m_D \cdot (c_D \cdot T + \Delta h_v - p_D \cdot v_D). \quad (22)$$

Über die partiellen Ableitungen von (20) und Gleichsetzen mit (18) erhält man nach Umstellung eine Differentialgleichung für $\frac{dT_k}{dt}$ die die zeitliche Änderung der Lufttemperatur T_k der Kabine beschreibt [43]⁴:

$$\frac{dT_k}{dt} = \frac{-\sum \dot{Q}_K + \dot{H}_{Zuluft} + \dot{H}_{Abluft} + \dot{H}_{Insassen} - \frac{dm_D}{dt} \cdot (c_D \cdot T_k + \Delta h_v)}{m_L \cdot c_L + m_D \cdot c_D}. \quad (23)$$

2.1.3.3 Relative Luftfeuchte und Taupunkt

Neben der Lufttemperatur stellt die relative Luftfeuchtigkeit φ eine weitere zentrale Regelgröße des Kabinenklimas dar. Die relative Luftfeuchtigkeit beschreibt das Verhältnis des aktuellen Wasserdampfgehalts der Luft zum maximal möglichen Wasserdampfgehalt bei gleicher Temperatur und gleichem Druck. Ein gegebenes Volumen an feuchter Luft kann nur eine begrenzte Menge von Wasser als Wasserdampf aufnehmen. Der Maximalwert dieser Wassermenge hängt lediglich von der Temperatur ab. Hat eine Luftmenge diesen Maximalwert erreicht, beträgt die relative Luftfeuchtigkeit 100 %. Wird diese Menge überschritten, so tritt bei positiven Temperaturwerten die Kondensation zu flüssigem Wasser bzw. bei negativen Temperaturwerten die Resublimation zu Eis auf [58]. Dies führt im Falle der Fahrzeugklimatisierung zu den unerwünschten Effekten des Scheibenbeschlags, der Scheibenvereisung bzw. der Vereisung am Verdampfer. Die relative Luftfeuchtigkeit wird häufig über das Verhältnis des Partialdrucks des Wasserdampfes p_w zum Sättigungspartialdruck p_w^s beschrieben:

$$\varphi = \frac{p_w}{p_w^s}. \quad (24)$$

Der Partialdruck des Wasserdampfes ist, gemäß dem Gesetz von Dalton, abhängig von der spezifischen Gaskonstanten R_w , dem Volumen V , der Temperatur T und der Masse des Wasserdampfes m_w :

$$p_w = \frac{m_w \cdot R_w \cdot T}{V}. \quad (25)$$

Die Änderung der relativen Luftfeuchte der Kabinenluft kann über die Änderung der Wasserdampfmasse m_w in der Kabine bestimmt werden:

$$\frac{dm_w}{dt} = \dot{m}_g \cdot (x_G - x_K) + \dot{m}_a \cdot (x_A - x_K) + \dot{m}_{w,T}. \quad (26)$$

⁴ Unter der Annahme, dass der Luftdruck in der Kabine und die Masse der trockenen Luft konstant sind.

Hierbei ist \dot{m}_g der durch das Gebläse eingebrachte Luftmassenstrom, x_G der Wassergehalt dieses Luftmassenstroms und x_K der Wassergehalt der Kabinenluft. Weiterhin ist \dot{m}_a der Luftmassenstrom der Atemluft, x_A der Wassergehalt der Atemluft und $\dot{m}_{w,T}$ der durch Transpiration verursachte Wasserdampfstrom. [43]

Der Wassergehalt beschreibt dabei das Verhältnis von der Masse des Wasserdampfes m_w zur Masse der trockenen Luft m_l mit

$$x = \frac{m_w}{m_l}. \quad (27)$$

Die Gefahr des Scheibenbeschlags kann über die Taupunkttemperatur $\tau(\varphi, T_i)$ der Innenluft quantifiziert werden. Die Taupunkttemperatur ist die Temperatur bei gegebenem Wassergehalt, bei der die relative Luftfeuchtigkeit 100 % beträgt und sich somit Wasserdampf abscheidet. Ist die Scheibentemperatur niedriger als die Taupunkttemperatur der Innenluft, so bildet sich Beschlag an der Scheibe. Die Taupunkttemperatur lässt sich unter Verwendung der Magnus-Formel berechnen. Bei einem Sättigungsdampfdruck über Wasser im Temperaturbereich zwischen -45°C und 60°C gilt

$$\tau(\varphi, T_i) = 243,12^\circ\text{C} \cdot \frac{\frac{22,46 \cdot T_i}{243,12^\circ\text{C} + T_i} + \ln \varphi}{\frac{22,46 \cdot 243,12^\circ\text{C}}{243,12^\circ\text{C} + T_i} - \ln \varphi}. \quad (28)$$

2.1.4 Experimentelle Modellbildung durch künstlich neuronale Netze

Wie bereits einleitend beschrieben, ist eine vollständige theoretische Modellbildung nur möglich, wenn die physikalischen Gesetzmäßigkeiten vollständig erfasst werden können und sämtliche Parameter des Systems bekannt sind. Sind diese Voraussetzungen nicht gegeben, so kann eine experimentelle Modellbildung als Ergänzung oder Alternative zur theoretischen Modellbildung in Betracht gezogen werden. In der Regelungstechnik wird diese Art der Modellbildung auch als (experimentelle) Systemidentifikation bezeichnet. Für linearisierbare Prozesse können nichtparametrische Identifikationsmethoden wie die Frequenzgangmessung mit periodischen Testsignalen, Fourier-, Korrelations- oder Spektralanalyse eingesetzt werden. Ist die Modellstruktur a priori bekannt, können parametrische Identifikationsmethoden wie Kennwertermittlung durch Messung der Antwortfunktion für einfache Prozesse, Referenzmodell- oder Parameterschätzmethoden eingesetzt werden. Ein Überblick dieser Verfahren für mechatronische Systeme ist in [53] zu finden. Zur vollständigen Systemidentifikation komplexer nichtlinearer Prozesse bei unbekannter Prozessstruktur sind diese klassischen experimentellen Ansätze i.d.R. weniger geeignet. Eine Alternative hierzu bieten Verfahren des maschinellen Lernens ins Besondere die Modellbildung durch künstlich neuronale Netze (KNN). Hierfür werden im Folgenden die Grundlagen kurz vorgestellt. Eine ausführlich Beschreibung ist in [65], [66] und [67] zu finden, worauf auch die folgenden Unterkapitel basieren.

2.1.4.1 Einlagige Perzeptrons

Die einfachste Form eines neuronalen Netzes stellt ein einlagiges Perzeptron dar. Ein einlagiges Perzeptron besteht aus einem Eingangsvektor $\vec{x} = [x_1, x_2, \dots, x_u]^T$ und einer Anzahl v von künstlichen Neuronen. Ein künstliches Neuron besteht aus Eingangsgewichten w_{ij} , einer Übertragungsfunktion Σ und einer Aktivierungsfunktion φ . Zusätzlich wird i.d.R. ein zusätzlicher Eingang $x_0 = 1$, der auch als

Bias bzw. on-Neuron bezeichnet wird, verwendet⁵. Die Gewichte w_{ij} bestimmen den Einfluss eines Eingangs x_i auf ein Neuron, wobei jeder Eingang einen Einfluss auf jedes Neuron hat. Sämtliche Gewichte eines Neurons können kompakt in Vektornotation \vec{w}_j , die des einlagigen Perzeptrons kompakt in Matrixnotation W mit

$$W = [\vec{w}_1, \vec{w}_2, \dots, \vec{w}_u] = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1v} \\ w_{21} & w_{22} & \dots & w_{2v} \\ \vdots & \vdots & \ddots & \vdots \\ w_{u1} & w_{u2} & \dots & w_{uv} \end{bmatrix} \quad (29)$$

dargestellt werden. Durch die Übertragungsfunktion, eine gewichtete Summenfunktion, wird die Netzeingabe net_j eines Neurons j mit

$$net_j = \sum_{i=1}^u x_i w_{ij} = \vec{x}^T \vec{w}_j. \quad (30)$$

berechnet. Durch die Aktivierungsfunktion wird die Ausgabe eines Neurons o_j berechnet:

$$o_j = \varphi(net_j). \quad (31)$$

Als Aktivierungsfunktionen werden Sprungfunktionen, lineare oder stückweise lineare Funktionen, nichtlineare Funktionen und Kombinationen aus diesen verwendet. Tabelle 1 zeigt die am häufigsten verwendeten Aktivierungsfunktionen.

Name	Gleichung	Ableitung
Identität	$id(x) = x$	$id'(x) = 1$
Sprungfunktion (Heaviside-Funktion)	$H(x) = \begin{cases} 0 & \text{für } x < 0 \\ 1 & \text{für } x \geq 0 \end{cases}$	$H'(x) = \begin{cases} 0 & \text{bei } x \neq 0 \\ nd & \text{bei } x = 0 \end{cases}$
Logistische Funktion (Sigmoid/Softstep)	$sig(x) = \frac{1}{1 + e^{-x}}$	$sig'(x) = sig(x)(1 - sig(x)) = \frac{1}{1 + e^{-x}} \left(1 - \frac{1}{1 + e^{-x}}\right)$
Tangens Hyperbolicus	$tanh(x) = 1 - \frac{2}{e^{2x} + 1}$	$tanh'(x) = 1 - (tanh(x))^2 = 1 - \left(1 - \frac{2}{e^{2x} + 1}\right)^2$
Rectified Linear Unit (ReLU)	$f(x) = \begin{cases} 0 & \text{für } x < 0 \\ x & \text{für } x \geq 0 \end{cases}$	$f'(x) = H(x) = \begin{cases} 0 & \text{für } x < 0 \\ 1 & \text{für } x \geq 0 \end{cases}$
Parametric ReLU (Leaky ReLU)	$f(x) = \begin{cases} \alpha x & \text{für } x < 0 \\ x & \text{für } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} \alpha & \text{für } x < 0 \\ 1 & \text{für } x \geq 0 \end{cases}$
Scaled Exponential Linear Unit (SELU)	$f(x) = \lambda \begin{cases} \alpha(e^x - 1) & \text{für } x \leq 0 \\ x & \text{für } x > 0 \end{cases}$	$f'(x) = \lambda \begin{cases} \alpha(e^x - 1) + \alpha & \text{für } x < 0 \\ 1 & \text{für } x \geq 0 \end{cases}$

Tabelle 1 Häufig verwendete Aktivierungsfunktionen

Um eine Funktion zu approximieren, werden die Gewichte des Perzeptrons iterativ solange angepasst, bis vorgegebene Eingabewerte \vec{x} auf Ausgabewerte \vec{o} in hinreichender Genauigkeit zu ebenfalls

⁵ Alternativ kann hierbei auch ein Schwellwert θ_j der Aktivierungsfunktion eingesetzt werden.

vorgegebenen Zielausgabewerten \vec{t} (Targets bzw. Teaching Input) abgebildet werden können. Ein Paar von zugehörigen Eingabewerten \vec{x} und Zielausgabewerten \vec{t} bezeichnet man als (gelabeltes) Trainings-sample. Da für das Lernen in jedem Rechenschritt ein Vergleich zwischen tatsächlichen und erwünschten Ausgabewerten erforderlich ist, spricht man hierbei von Verfahren des Überwachten Lernens. Das Lernen erfolgt anhand einer Stichprobe, also einer Menge von Trainings-samples. Als Lernverfahren können Gradientenabstiegsverfahren verwendet werden. Ein Spezialfall hiervon ist die sogenannte Deltaregel bei linearen Aktivierungsfunktionen. Diese ist in der Informatik auch als Widrow-Hoff-Verfahren oder in der Signalverarbeitung als Least-Mean-Squares-Verfahren (LMS) bekannt. Hierbei wird die Identität als Aktivierungsfunktion verwendet. Die Überwachung des Lernfortschritts erfolgt beim Gradientenabstiegsverfahren durch eine quadratische Fehlerfunktion L (auch Loss bzw. Lossfunktion):

$$L_j = (t_j - o_j)^2 = (t_j - \varphi(\text{net}_j))^2 = (t_j - \varphi(\vec{x}^T \vec{w}_j))^2. \quad (32)$$

Das Lernen erfolgt durch iterative Minimierung der Lossfunktion für jedes Neuron. In jedem Iterationsschritt n werden die Eingangsgewichte w_{ij} eines Neurons durch ein Δw_{ij} so angepasst, dass sich der Fehler des Outputs o_j bzgl. des Targets t_j für die gegebenen Eingangswerte \vec{x} verringert:

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}. \quad (33)$$

Die Änderung Δw_{ij} eines Gewichtes ergibt sich durch Berechnung des negativen Gradientenabstiegs der Lossfunktion. Hierbei muss die Lossfunktion partiell nach dem jeweiligen Gewicht abgeleitet werden. Hierdurch ergibt sich

$$\Delta w_{ij} = -\frac{\partial L_j}{\partial w_{ij}}. \quad (34)$$

Aufgrund der Kettenregel ergibt sich für die partielle Ableitung der Lossfunktion nach dem Gewicht w_{ij} der Gradient

$$\begin{aligned} \frac{\partial L_j}{\partial w_{ij}} &= \frac{\partial L_j}{\partial o_j} * \frac{\partial o_j}{\partial \text{net}_j} * \frac{\partial \text{net}_j}{\partial w_{ij}} = \frac{\partial (t_j - o_j)^2}{\partial o_j} * \frac{\partial \varphi(\text{net}_j)}{\partial \text{net}_j} * \frac{\partial \vec{x}^T \vec{w}_j}{\partial w_{ij}} \\ &= 2(o_j - t_j) * \frac{\partial \varphi(\text{net}_j)}{\partial \text{net}_j} * x_i. \end{aligned} \quad (35)$$

Wird die Identität als Aktivierungsfunktion verwendet und zur Skalierung der Konvergenz der Lernfaktor bzw. die Lernrate μ eingeführt, ergibt sich die Deltaregel

$$w_{ij}(n+1) = w_{ij}(n) + \mu (t_j - o_j) x_i \quad (36)$$

als Lernverfahren für ein einzelnes Gewicht. Für sämtliche Eingangsgewichte eines Neurons lautet damit die Deltaregel in kompakter Vektorschreibweise

$$\vec{w}_j(n+1) = \vec{w}_j(n) + \mu (t_j - o_j) \vec{x}. \quad (37)$$

Bei der Verarbeitung der Trainingsdaten und Anpassung der Gewichte wird zwischen Online- und Offline-Lernen unterschieden. Beim Online-Lernen erfolgt die Gewichtsänderung durch die Gradientenbildung der Fehlerfunktion für ein einzelnes Trainings-sample (wie oben gezeigt). Hierfür können die Trainings-samples der Stichprobe innerhalb eines Iterationsschrittes des Lernverfahrens inkrementell

abgearbeitet oder stochastisch ausgewählt (Stochastisches Gradientenabstiegsverfahren - SGD) werden. Beim Offline-Lernen erfolgt die Verarbeitung der Trainingsamples stapelweise, weshalb dies auch als Batch-Gradientenverfahren bezeichnet wird. Hierbei erfolgen in jedem Iterationsschritt die Gradientenbildung und Gewichtsänderung für die gesamte Stichprobe. Erfolgt die Verarbeitung zwar stapelweise aber nur für einen Teil der gesamten Stichprobe, spricht man vom sogenannten Mini-batch-Gradientenverfahren.

Da einlagige Perzeptrons bereits an der Abbildung einfacher Funktionen wie einem XOR-Gatter scheitern, sind sie eher zur Klassifizierung oder zur Modellbildung sehr einfacher (statischer) Systeme geeignet [68]. Um komplexe Systeme zu modellieren, können diese aber, in einer Reihenschaltung mehrerer einlagiger Perzeptrons, zu mehrlagigen Perzeptrons (MLP) erweitert werden. Hierbei verfügt das neuronale Netz dann neben einer Eingabeschicht, über mindestens eine verdeckte Schicht (hidden layer) mit mehreren Neuronen sowie über eine Ausgabeschicht mit mindestens einem Neuron. Besteht ein künstlich neuronales Netz aus zwei oder mehreren verdeckten Schichten, so bezeichnet man dies als Deep-Learning-Netz [65]. Ist der Signalfluß innerhalb eines MLP direkt von der Eingabeschicht über die verdeckten Schichten zur Ausgabeschicht ohne Rückkopplungen gerichtet, so spricht man auch von (mehrlagigen) Feed-Forward-Netzen.

2.1.4.2 Feed-Forward-Netze

Mehrlagige Feed-Forward-Netze haben gegenüber einlagigen Perzeptrons ein wesentlich höheres Abstraktionsvermögen. Das universelle Approximationstheorem (universal approximation theorem) besagt, dass ein mehrlagiges Feed-Forward-Netz, unter gewissen Einschränkungen in den Aktivierungsfunktionen⁶, jede Funktion approximieren kann, wenn die verdeckten Schichten ausreichend viele Neuronen besitzen. Das Theorem wurde durch Hornik in [69] und Cybenko in [70] bestätigt. Allerdings kann die Breite dieses Netzes dabei unhandhabbar groß werden, so dass ein Erlernen der Gewichte nicht möglich sein könnte. Für sehr komplexe Funktionen kann dieses Problem durch die Erhöhung der Anzahl der verborgenen Schichten tangiert werden. In tiefen neuronalen Netzen ist die Parametereffizienz wesentlich höher als in flachen, wodurch exponentiell weniger Neuronen benötigt werden (vgl. hierzu [65] S.271). Problematisch ist bei mehrlagigen Feed-Forward-Netzen, dass die Zielausgabewerte der einzelnen Neuronen in den verdeckten Schichten nicht direkt vorliegen. Hierdurch kann der Ausgabefehler und damit auch die Lossfunktion nicht direkt berechnet werden. Ein Lösungsansatz hierfür ist die Verwendung des, häufig als Backpropagation bezeichneten, Gradienten-Verfahrens des Automatischen Differenzierens (AD) im Rückwärtsmodus (Reverse Mode). Das Verfahren beruht auf dem Prinzip des dynamischen Programmierens und der Anwendung der Kettenregel. Hierbei wird zunächst durch Vorwärtsrechnen der Trainingseingangswerte der Fehler der Gesamtnetzausgabe für die aktuell vorliegenden Gewichte der einzelnen Schichten berechnet (Forward-Propagation). Aus dem Fehler der Ausgabeschicht kann ein Fehlersignal δ_k bezogen auf die Netzeingabe der Ausgabeschicht net_k bestimmt werden:

$$\delta_k = - \frac{\partial L_k}{\partial net_k} = - \frac{\partial L_k}{\partial o_k} * \frac{\partial o_k}{\partial net_k} = (t_k - o_k) * \frac{\partial \varphi(net_k)}{\partial net_k}. \quad (38)$$

Die Netzeingabe der Ausgabeschicht net_k berechnet sich aus der Netzausgabe der vorherigen Schicht o_j und den Gewichten der letzten Schicht w_{jk} .

⁶ In den verdeckten Schichten kann z.B. eine sigmoide Aktivierungsfunktion und in der Ausgabeschicht eine lineare Aktivierungsfunktion verwendet werden.

Hieraus können analog zu (33) direkt die Gewichts Anpassung der Gewichte der letzten Schicht mit

$$w_{jk}(n+1) = w_{jk}(n) + \mu \delta_k o_j = w_{jk}(n) + \mu (t_k - o_k) o_j \quad (39)$$

berechnet werden. Das Fehlersignal δ_k kann dann auf das Fehlersignal der vorherliegenden Schicht δ_j mit

$$\delta_j = \sum (w_{jk}(n) \delta_k) * \frac{\partial \varphi(\text{net}_j)}{\partial \text{net}_j} \quad (40)$$

zurückgerechnet werden. Hieraus können wiederum die Gewichte w_{ij} der vorherliegenden Schicht mit

$$w_{ij}(n+1) = w_{ij}(n) + \mu \delta_j o_i \quad (41)$$

berechnet werden. Das Verfahren wird rückwärts über alle Schichten durchgeführt bis die Eingangsschicht des Gesamtnetzes erreicht wird. Eine sehr effiziente Umsetzung des Verfahrens kann durch die Verwendung von Berechnungsgraphen, wie z.B. im ML-Framework TensorFlow erfolgen. Die mathematischen Operationen werden hierbei als Knoten und der Datenfluss als Kanten beschrieben.

Das Backpropagation-Verfahren hat drei wesentliche Probleme. Das erste wesentliche Problem ist das des schwindenden und explodierenden Gradienten (vanishing/exploding) bzw. des Neuronensterbens. Die beiden anderen Probleme, die bei fast allen Methoden des maschinellen Lernens auftreten, sind das Bias-Varianz-Dilemma und das der Konvergenzgeschwindigkeit. Das Problem der schwindenden und explodierenden Gradienten tritt vor allem bei ungünstigen Kombinationen der Aktivierungsfunktionen und Startinitialisierungen der Gewichte auf. Bei Aktivierungsfunktionen mit Sättigung wie der Sigmoidfunktion oder dem Tangens Hyperbolicus ist der Gradient bei hohen und niedrigen Netzeingaben nahe Null. Das zurückpropagierte Fehlersignal δ_k wird in diesen Fällen sehr klein. Da das Fehlersignal der vorderen Schichten über das Produkt des Fehlersignals der jeweils hinteren Schicht berechnet wird, werden die Fehlersignale von Schicht zu Schicht kleiner bis in den ersten Schichten keine Änderung der Gewichte mehr erfolgen kann. Dies kann bei tieferen Netzen dazu führen, dass die ersten Schichten überhaupt nicht trainiert werden können. Das entgegengesetzte Problem der explodierenden Gradienten tritt auf, wenn die zurückpropagierten Fehlersignale größer als Eins werden. Dies führt dazu, dass das der Lernvorgang instabil wird und sich die Gewichte des Netzes auf nicht mehr darstellbare Größe erhöhen. Um die Probleme der schwindenden und explodierenden Gradienten zu bekämpfen, gibt es eine Reihe von Ansätzen.

Ein Ansatz ist es, durch eine geeignete Startinitialisierung der Gewichte eine Art Gleichgewicht der Varianz der Eingaben und Ausgaben einer Schicht herzustellen (Fan-in und Fan-out). In [65] wird nach diesem Ansatz, auch als Initialisierung nach Xavier bezeichnet, die Berechnung der Startinitialisierung der Gewichte für verschiedene Aktivierungsfunktionen in Abhängigkeit der Anzahl der eingehenden und ausgehenden Verbindungen einer Schicht gezeigt. Ein weiterer Ansatz ist die Verwendung von nichtsättigenden Aktivierungsfunktionen. Hierbei werden modifizierte ReLus wie leaky ReLu und ELU verwendet. Diese vermeiden das beim ReLu auftretende Problem des Neuronensterbens, indem sie im negativen Bereich eine Teilfunktion mit positiver Steigung verwenden. Die auf der Exponentialfunktion basierenden ELU haben gegenüber den stückweise linearen leaky ReLu den Nachteil eines höheren Berechnungsaufwandes, was aber durch eine schnellere Konvergenz des resultierenden Lernvorgangs mehr als kompensiert werden kann. Nachteilig ist allerdings der Berechnungsaufwand bei der

Anwendung des trainierten Netzes, der in einer höheren Laufzeit gegenüber Netzen mit stückweise linearen Aktivierungsfunktionen resultiert. Durch eine geeignete Kombination von Startinitialisierung und nichtsättigenden Aktivierungsfunktionen kann sich der Lernvorgang am Beginn stabilisieren und diesen damit wesentlich beschleunigen, aber das Auftreten von schwindenden und explodierenden Gradienten im fortgeschrittenen Lernvorgang nicht verhindern. Hierfür wurde in [71] mit der Batch-Normalisierung (BN) eine weitere Technik eingeführt. Hierbei wird in jeder Schicht vor der Aktivierungsfunktion eine Operation eingeführt, die sämtliche Netzeingaben net_j auf Null zentriert, normalisiert und anschließend skaliert und verschiebt. Die Parameter der Operation (Mittelwert und Standardabweichung) werden für jede Schicht aus dem aktuellen Minibatch gemittelt. Zum Testen und Anwenden des trainierten Netzes werden die Parameter dann aus dem Gesamtbatch bestimmt. Das Verfahren ist so effektiv, dass sogar Aktivierungsfunktionen mit Sättigung verwendet werden können. Nachteilig wirkt sich hierbei wieder der erhöhte Rechenaufwand durch die hinzugefügten Operationen auf die Laufzeit der späteren Verwendung des trainierten Netzes aus. Eine aktuelle Alternative hierzu bieten sogenannte selbstnormalisierende Neuronale Netze (SNN). Hierbei wird als Aktivierungsfunktion das in Tabelle 1 dargestellte SELU als Aktivierungsfunktion verwendet. In [72] konnte gezeigt werden, dass durch die Verwendung dieser Aktivierungsfunktion die Ausgaben jeder Schicht bei Netzeingaben mit einem Mittelwert von Null und einer Standardabweichung von Eins Richtung einer Verteilung mit einem Mittelwert von Null und einer Standardabweichung von Eins konvergieren. Dies führt zu einer Vermeidung von schwindenden oder explodierenden Gradienten. Hierdurch wird der Lernvorgang sehr robust und es können sehr tiefe Netze verwendet werden. Der Rechenaufwand ist im Vergleich zur Batchnormalisierung wesentlich geringer. Außerdem reduzieren sie, durch eine stark regularisierende Wirkung, das im Folgenden behandelte Problem des Bias-Varianz-Dilemmas. Weitere Möglichkeiten zur Eindämmung des schwindenden und explodierenden Gradientenproblems ist die Verringerung der Mini-Batch-Größe, die L1- oder L2-Regularisierung, Gradient-Clipping und Transfer-Learning.

Das zweite wesentliche Problem des Lernens neuronaler Netze, wie auch der meisten Verfahren des maschinellen Lernens im Allgemeinen ist das Bias-Varianz-Dilemma. Entspricht die Modellkomplexität nicht der Komplexität der abzubildenden Funktion, so kann dies zu einer Überanpassung (Overfitting) oder eine Unteranpassung (Underfitting) führen. Bei Unteranpassung kann das Netz nach dem Training die Trainingseingangsdaten nicht mit ausreichender Genauigkeit auf die Trainingseingangsdaten abbilden. Bei einer Überanpassung gelingt dies zwar, aber das Netz kann nicht generalisieren, d.h. ungesehene Testeingangsdaten nicht mit ausreichender Genauigkeit auf die zugehörigen Test- bzw. Validierungstargets abbilden. Der Erwartungswert des quadratischen Fehlers des Ausgabewertes eines Netzes für eine ungesehene Stichprobe kann als Summe von Bias, Varianz und eines Rauschtherms mit

$$E[(t - o)^2] = Bias[o]^2 + Var[o] + \sigma^2 = E[(t - o)]^2 + E[(o - E[o])^2] + \sigma^2 \quad (42)$$

dargestellt werden. Der Bias-Term beschreibt die Verzerrung und kann also als Schwerpunkt der Verteilung des Fehlers interpretiert werden. Der Varianz-Term beschreibt die Streuung der Testausgabewerte um ihren Erwartungswert. Der dritte Term beschreibt die Streuung eines durch Rauschen verursachten, nichtreduzierbaren Fehlers mit dem Erwartungswert von Null. Durch eine Erhöhung der Modellkomplexität, durch die Erhöhung der Anzahl der Neuronen, kann der Bias-Term verringert werden. Dies birgt aber immer das Risiko der Erhöhung des Varianz-Terms, was wiederum zu einer Überanpassung führt. Um dieses Risiko zu minimieren, können verschiedene Regularisierungstechniken wie die L1- oder L2-Regularisierung, Dropout-Layer, Early Stopping eingesetzt oder SELU-Aktivierungs-

funktionen verwendet werden. Bei der L1- oder L2 -Regularisierung wird der Lossfunktion ein Strafterm hinzugefügt, der die Größe der Gewichte beschränkt. Bei der Dropout-Technik werden mit einer gewählten Wahrscheinlichkeit (Drop-Out-Rate) Neuronen einer Schicht in den Trainingsiterationen deaktiviert und so deren Gewichte nicht angepasst. Beim Early Stopping wird der Trainingsvorgang abgebrochen, sobald bei einer parallel durchgeführten Validierung der Fehler der Validierungsdaten steigt.

Das dritte wesentliche Problem betrifft die Konvergenzgeschwindigkeit des Trainingsvorgangs. Ist die Lernrate zu groß, konvergiert das Verfahren möglicherweise nicht. Ist die Lernrate zu klein, so konvergiert das Verfahren extrem langsam. Um diesem Problem zu begegnen, kann die Lernrate dynamisch angepasst werden und/oder auf dem Gradientenverfahren basierende schnellere Optimierungsverfahren verwendet werden. Das dynamische Anpassen der Lernrate wird auch als Scheduling bezeichnet. Hierbei unterscheidet man statische und dynamische Methoden. Statische Methoden verändern die Lernrate in Abhängigkeit des Trainingsiterationsschrittes linear oder exponentiell. Dynamische Methoden verändern die Lernrate in Abhängigkeit der Änderung des Validierungsfehlers. Die einfachste Variante schnellerer Optimierungsverfahren ist das Momentum-Verfahren. Hierbei wird der Korrekturterm zur Änderung der Gewichte als Moment bezeichnet. Das Moment $M(n)$ für einen Lernschritt berechnet sich mit

$$M(n) = \beta * M(n - 1) + \mu \frac{\partial L}{\partial W} \quad (43)$$

aus der Summe des mit einem Hyperparameter β multiplizierten Moments $M(n - 1)$ des letzten Schrittes und des aktuellen Gradienten, multipliziert mit der Lernrate μ . Die Anpassung der Gewichte erfolgt analog zum Gradientenverfahren:

$$W(n) = W(n - 1) + (-M(n)). \quad (44)$$

Man kann in Analogie zur Kinematik die Anpassung der Gewichte als Geschwindigkeit interpretieren, die durch eine vorhandene Reibung (β) verringert und durch eine Beschleunigung ständig angepasst wird. Hierdurch können dann durch den so als kinetische Energie interpretierbaren Schwung geometrische Sattelpunkte überwunden werden. Eine leichte Verbesserung des Verfahrens kann durch die Variante des beschleunigten Gradienten nach Nesterov (NAG) erreicht werden [73]. Hierbei wird der Gradient an der um βM verschobenen Position ausgewertet, wodurch das Verfahren beschleunigt wird.

Eine weitere Variante der Gradientenverfahren sind Verfahren mit adaptiven Subgradienten. Hierbei wird anstelle eines Momentes ein als Subgradient bezeichneter quadriertes Gradient aufakkumuliert. Der Korrekturterm wird aus dem Quotienten vom aktuellen Gradienten und dem Subgradienten gebildet. Der Subgradient skaliert somit den Korrekturterm an steilen Stellen herunter und an flachen Stellen hoch. Eine aktuell häufig eingesetzte Variante dieser Verfahren ist die Root-Mean-Square-Propagation (RMSProp). Hierbei wird die Akkumulation des Subgradienten durch einen weiteren Hyperparameter β , welcher auch als Zerfallsrate bezeichnet wird, gesteuert.

Eine Kombination aus Momentenvariante und der adaptiven Subgradienten liefert das Adaptive-Moment-Optimizer-Verfahren (ADAM). Hierbei wird in jedem Iterationsschritt sowohl ein Moment als auch ein Subgradient akkumuliert. Der Korrekturterm zur Berechnung der Gewichte berechnet sich hierbei aus der Multiplikation der Lernraten mit dem Quotienten von Moment und Subgradient. Die

auf adaptiven Subgradienten basierenden Verfahren RMSProp und ADAM benötigen aufgrund des adaptiven Verhaltens kein Scheduling der Lernrate [65]. Die Wahl des "richtigen" Lernverfahrens hängt stark vom abzubildenden System und dem Einsatzzweck ab. Entsprechend des No-Free-Lunch-Theorem gibt es kein Verfahren, das generell für jegliche Problemstellung am besten geeignet ist. Feedforward-Netze eignen sich aufgrund der dargestellten Eigenschaften besonders zur Abbildung statischer Systeme. Sollen dynamische Systeme z.B. zur Prognose von Zeitreihen hiermit dargestellt werden, kann dies i.d.R. nur über die Sliding-Window-Technik⁷ erfolgen. Hierbei werden neben den aktuellen Werten der Eingangsgrößen, ebenfalls vergangene Werte der Eingangsgrößen als zusätzlich Eingänge des Netzes hinzugefügt. Der inhärente Zustand eines Systems kann dadurch nur indirekt abgebildet werden. Soll z.B. speicherndes Verhalten eines Systems direkt abgebildet werden, bieten sich hier rekurrente Netze als Alternative an.

2.1.4.3 Rekurrente Netze

Rekurrente neuronale Netze (RNN) besitzen im Gegensatz zu Feedforward-Netzen Rückkopplungen. Die einfachsten Varianten stellen partielle rekurrente Netze mit indirekten Rückkopplungen wie Jordan- und Elman-Netze dar. Diese Netze besitzen sogenannte Kontextzellen als zusätzliche Eingangsgrößen des Netzes. Die Rückkopplung erfolgt über die Kontextzellen, indem diese mit den letzten Werten der Ausgabeschicht (Jordan-Netze) oder der verdeckten Schicht (Elman-Netze) aus dem vorangegangenen Prognoseschritt belegt werden. Die Kombination von Jordan-Netzen mit der Sliding-Window-Technik wird auch als NARX (nonlinear autoregressive networks with exogenous inputs) bezeichnet. Diese Verfahren werden im Bereich der Systemidentifikation zur Modellierung von Zeitreihen eingesetzt. Das Training von partiellen rekurrenten Netzen erfolgt ohne die Verwendung der Rückkopplung in einer seriellen Struktur. Hier werden die wahren Ausgaben des jeweils vorangegangenen Prognoseschritts anstelle der vorhergesagten Ausgabe verwendet. Dies hat zum einen den Vorteil, dass die korrekten Werte für die Kontextzellen zum Lernen verwendet werden. Andererseits kann hierdurch ein unmodifiziertes Backpropagation-Lernverfahren eingesetzt werden.

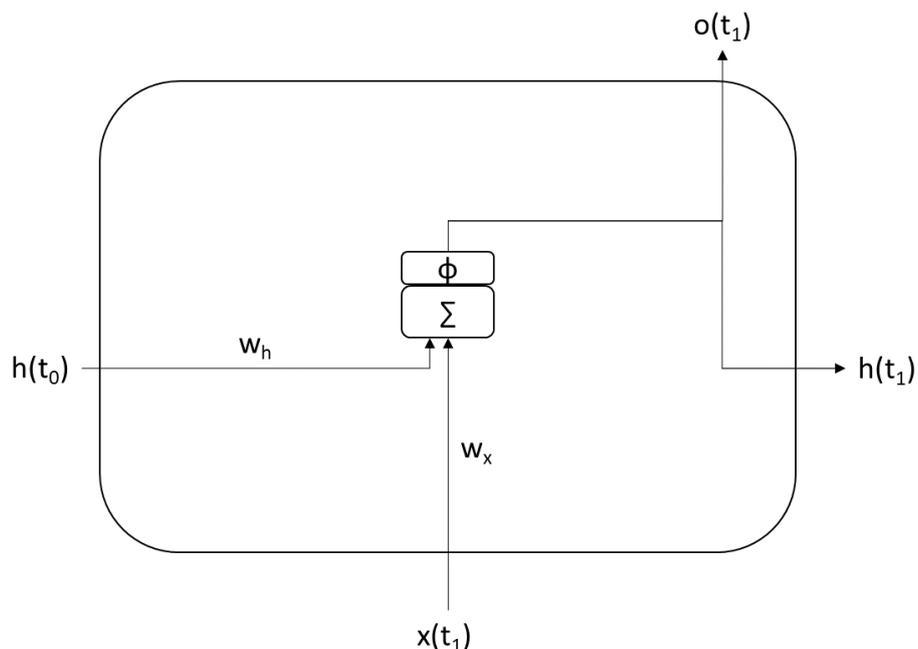


Abbildung 5 Aufbau einer rekurrenten (Gedächtnis)-Zelle

⁷ Diese Technik wird zum Teil auch als Time Delay Neural Network (TDNN) bezeichnet.

Eine verbreitete Variante zur Zeitreihenvorhersage stellen rekurrente Netze mit direkten Rückkopplungen dar. Dabei wird der jeweilige Netzeingang aus der Summe der gewichteten aktuellen Eingangsgrößen und einer gewichteten Summe der vorangegangenen Netzausgabe der Schicht berechnet. Im Gegensatz zu einem Feedforward-Netz ist somit ein zweiter Satz von Gewichten erforderlich. Da hierdurch im einzelnen Neuron ein Zustand h (hidden state) gespeichert wird, bezeichnet man diese auch als (Gedächtnis-)Zelle. Abbildung 5 zeigt den Aufbau einer rekurrenten Zelle.

Zur Vorwärtsberechnung der Netzausgaben werden die zeitlich aufeinanderfolgenden Eingänge (Frames) zu Sequenzen zusammengefasst und diese entlang der Zeit aufgerollt.

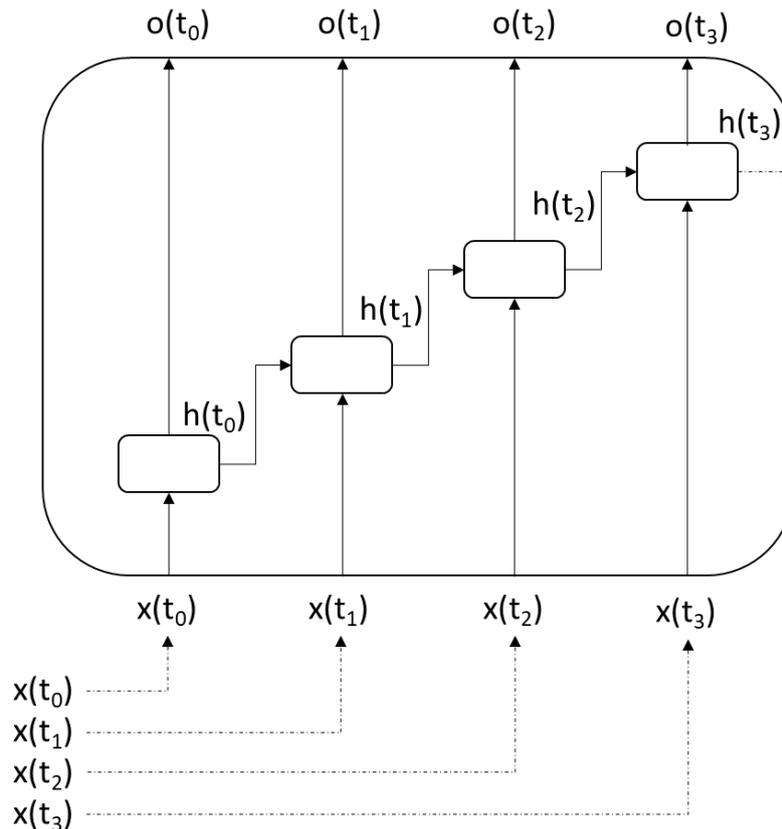


Abbildung 6 Aufrollen einer Sequenz innerhalb einer Zelle

Die Ausgabe der Zelle ist in der Regel wieder eine Sequenz (sequene-to-sequence prediction), kann sich aber auch auf den letzten Zustand beschränken (sequene-to-last prediction).

Der Lernvorgang erfolgt entsprechend des Backpropagation-Verfahrens für die aufgerollte Zelle in zurück gerichteter Reihenfolge und wird dementsprechend als backpropagation through time (BPTT) bezeichnet. Die in jedem einzelnen Schritt über die aufgerollte Zelle berechneten Fehlergradienten für die Eingangs- und Zustandsgewichtsvektoren werden dabei zur einmaligen Berechnung des Korrekturterms aufsummiert.

Eine weiterentwickelte Variante von rekurrenten neuronalen Netzen stellen die in [74] erstmalig veröffentlichten und seitdem weiterentwickelten LSTM-Netze (Long-Short-Time-Memory) dar. Im Gegensatz zu „gewöhnlichen“ rekurrenten Netzen besitzen LSTM-Netze LSTM-Zellen mit einem zusätzlichen Zustand. Neben dem Zustand h (hidden state), der den letzten Ausgabewert der Zelle speichert, wird ein Zustand c (cell state) in jedem Berechnungsschritt gespeichert. Der Zustand h kann als Kurzzeitgedächtnis und der Zustand c als Langzeitgedächtnis interpretiert werden. Für den grundsätzlichen

Aufbau von LSTM-Zellen sind in der Literatur leicht unterschiedliche Ansätze zu finden. Abbildung 7 zeigt in Anlehnung an [65] den inneren Aufbau einer LSTM-Zelle wie sie z.B. im Maschine-Learning-Framework TensorFlow eingesetzt wird. Die Aktualisierung der Zustände erfolgt hier über sogenannte Gates. Hierbei ist ein Input-Gate für die Filterung der Eingangswerte, ein Forget-Gate für die Filterung des Zellzustandes und eine Output-Gate für die Filterung der Ausgangswerte vorgesehen. Die Gates sind dafür verantwortlich, die Weiterleitung unrelevanter Informationen zu unterdrücken bzw. abzuschwächen. Dies erfolgt über die Gate-Aktivierung. Jede Gate-Aktivierung wird durch jeweils ein Perzeptron realisiert. Durch eine jeweils unterschiedlich gewichtete Summenfunktion wird hierbei die Netzeingabe aus dem Eingangssignal x und dem Zustand h aus dem letzten Zeitschritt berechnet. Über eine Gate-Aktivierungsfunktion, i.d.R. eine Sigmoid-Funktion, wird aus der Netzeingabe die Netzausgabe für das entsprechende Gate und somit die Gate-Aktivierung berechnet. Die Gate-Aktivierung wird anschließend mit dem zu filternden Signal multipliziert.

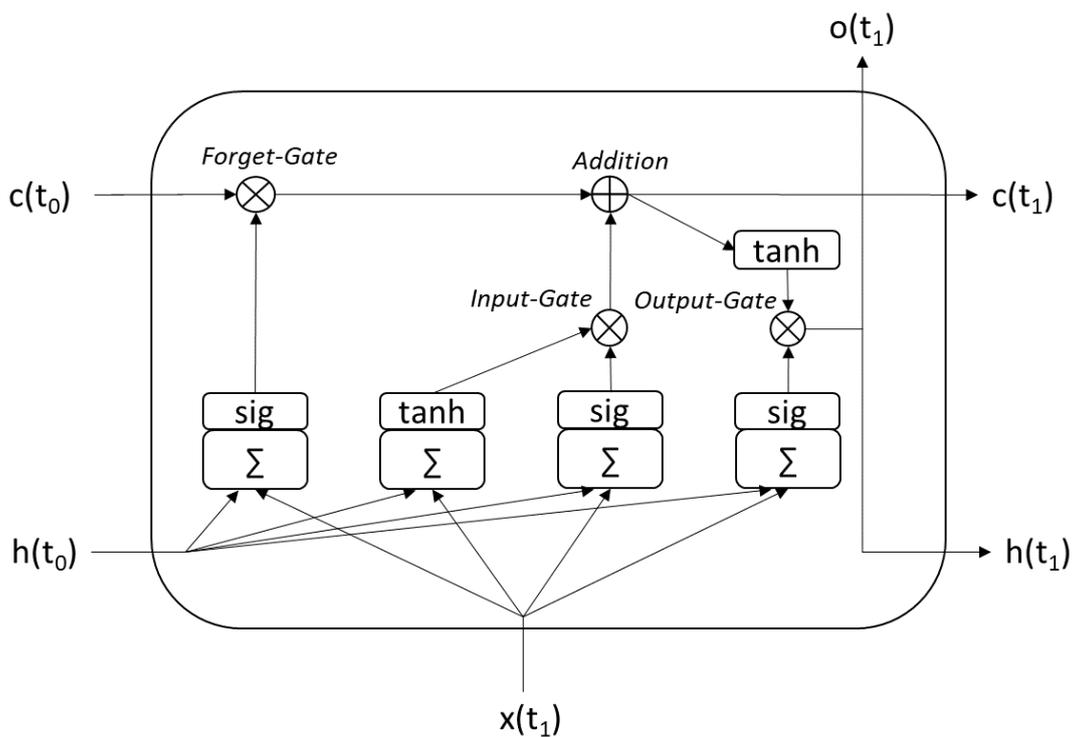


Abbildung 7 Aufbau einer LSTM-Zelle

Da aufgrund der Sigmoidfunktion die Gate-Aktivierung jeweils nur Werte zwischen 0 und 1 annehmen kann, wird der Betrag des passierenden Signals um 0 % bis 100 % reduziert. Entsprechend der Gates werden drei Arten von Signalen für Zellzustand, Zelleingang und Zellausgang unterschieden. Der Zelleingang wird wiederum über ein Perzeptron mit einer tanh-Aktivierungsfunktion aus dem Eingangssignal x und dem Zustand h berechnet und anschließend über das Input-Gate gefiltert. Der eingehende Zellzustand $c(t_0)$ aus dem letzten Zeitschritt wird über das Forget-Gate gefiltert. Um den neuen Zellzustand $c(t_1)$ zu berechnen, wird das gefilterte Zelleingangssignal mit dem gefilterten Zellzustandssignal addiert. Somit werden in jedem Berechnungsschritt durch das Forget-Gate Informationen im Langzeitgedächtnis entfernt (vergessen) und über das Input-Gate neue Informationen ins Langzeitgedächtnis hinzugefügt. Das Verhältnis des Behaltens alter Informationen und dem Hinzugewinnen neuer Informationen wird über die erlernten Eingangsgewichte des Input- und Forget-Gates bestimmt. Um das Ausgangssignal zu berechnen wird der aktuelle Zellzustand $c(t_1)$ über eine tanh-Aktivierungsfunktion

aktiviert und anschließend über das Output-Gate gefiltert. Das Ergebnis dieser Berechnung wird zum eine als Ausgabe der Zelle $c(t_1)$ und zur Speicherung des Zustands $h(t_1)$ verwendet.

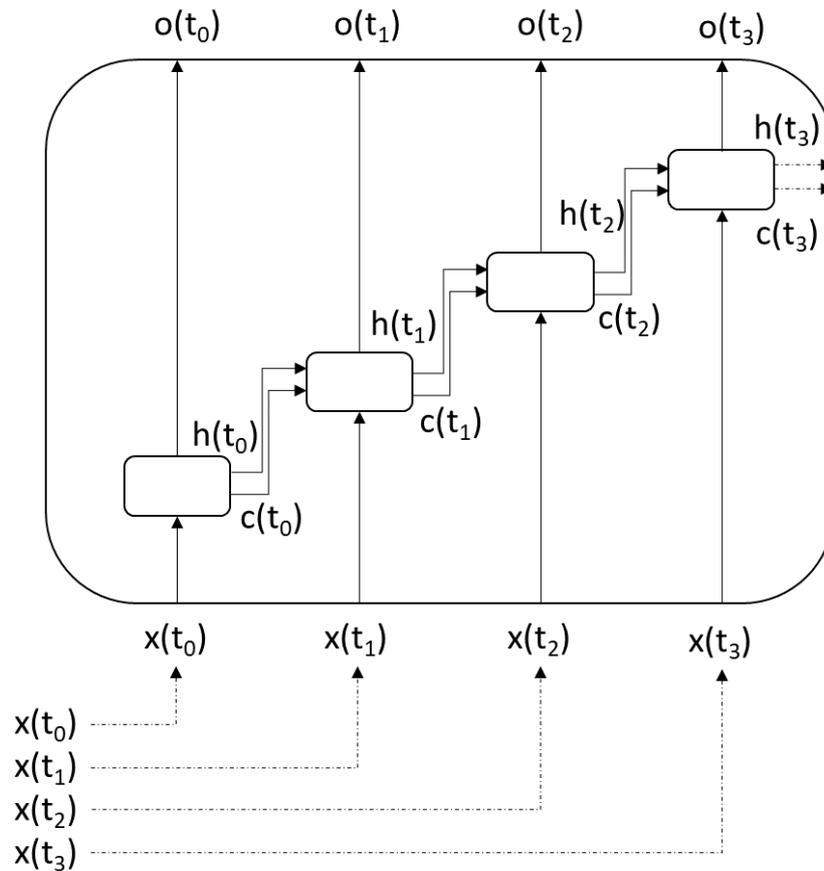


Abbildung 8 Aufrollen einer Sequenz innerhalb einer LSTM-Zelle

Die Vorwärtsberechnung der Netzausgaben erfolgt analog zu gewöhnlichen rekurrenten Netzen durch Aufrollen der zeitlich aufeinanderfolgenden Eingänge. Der Lernvorgang erfolgt ebenfalls analog zu gewöhnlichen rekurrenten Netzen entsprechend des Backpropagation-Verfahrens für die aufgerollte Zelle in zurück gerichteter Reihenfolge (BPTT).

2.2 Grundlagen der modellprädiktiven Regelung

Die Grundlagen der modellprädiktiven Regelung spielen eine zentrale Rolle dieser Arbeit, weshalb diese hier im Folgenden zusammengefasst aufgeführt werden. Eine ausführlichere Beschreibung der Grundlagen modellprädiktiver Regelung erfolgt [75], [6] und in der Anwendung in [9], sowie der nicht-linearen Lösungsansätze in [76], [77], [78] und [79], auf welchen die folgenden Unterkapitel inkl. deren Gleichungen basieren.

Die modellprädiktive Regelung, auch Model Predictive Control (MPC) oder Model Based Predictive Control (MBPC), ist weniger ein spezifischer Algorithmus als ein grundlegendes Konzept zur Lösung von Regelungsaufgaben. Dieses Konzept basiert auf der Verwendung eines Systemmodells zur Prädiktion von Zustandsgrößen und Systemausgängen für einen endlichen Zeithorizont. Unter Verwendung des Systemmodells werden durch Einbeziehung gemessener Zustands- und Ausgangsgrößen des Systems sowie einer frei wählbaren Stellgrößenfolge die Ausgänge des Systems für den endlichen Zeithorizont berechnet. Innerhalb dieses endlichen Zeithorizonts wird die Stellfolge der Stellgrößen des Systems so gewählt, dass ein Optimum bzgl. eines Gütefunktional erreicht wird. Das Gütefunktional beinhaltet hierbei die Abweichung der Regelgrößen zu ihren Sollwerten als auch den Stellaufwand der Stellgrößen bis zum Prognosehorizont. Das Verfahren unterscheidet sich insofern von einer klassischen Regelung, dass hier nicht vergangene Regelabweichungen zur Berechnung der zukünftigen Stellgrößen verwendet werden, sondern prognostizierte zukünftige Regelabweichungen. Von der ermittelten optimalen Stellgrößenfolge wird jeweils nur die erste Stellgröße zur Regelung des Systems verwendet und die Berechnung erneut durchgeführt. In jedem Abtastschritt erfolgt die Verschiebung des Zeithorizonts um einen Schritt in die Zukunft sowie eine Aktualisierung der Zustands- und Ausgangsgrößen für die folgende Prädiktion des aktuellen Prognosezeitfensters. Das ständige Aktualisieren der Zustands- und Ausgangsgrößen kann aus regelungstechnischer Sicht als Rückkopplung (Feedback) aufgefasst werden, welche den Regelkreis schließt und das Verfahren zu einer Regelung macht. Da in jedem Berechnungsschritt das Zeitfenster des aktuellen Prognosehorizonts verschoben wird, spricht man bei den verschiedenen Verfahren der modellprädiktiven Regelung auch vom Konzept des gleitenden Horizonts (receding horizon). Abbildung 9 und Abbildung 10 verdeutlichen das Konzept der modellprädiktiven Regelung.

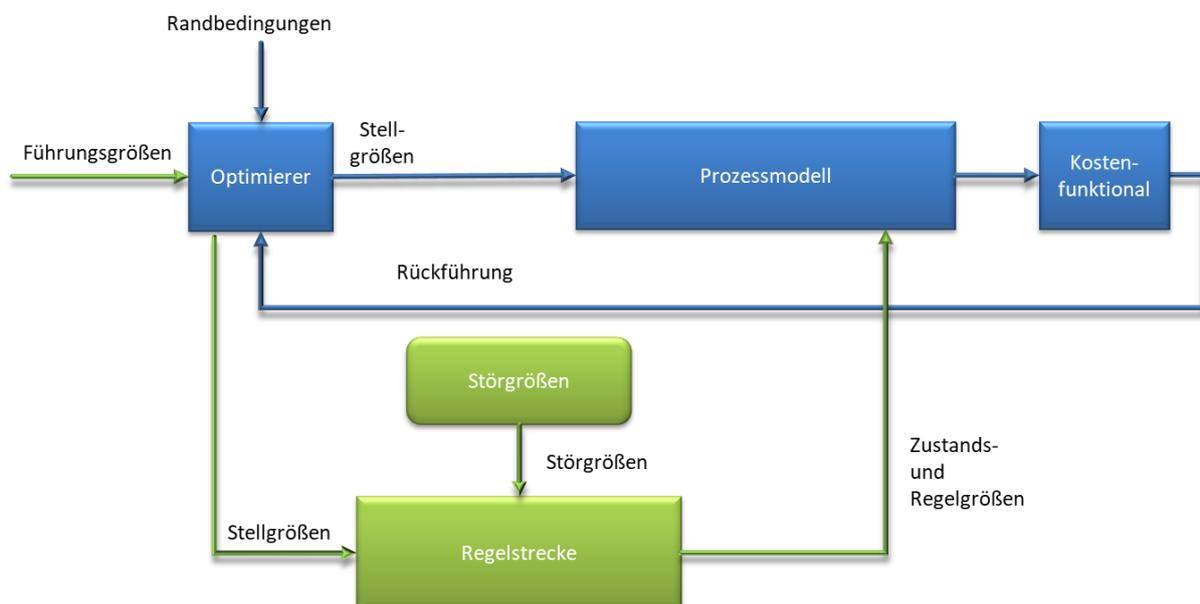


Abbildung 9 Wirkungsablauf der modellprädiktiven Regelung

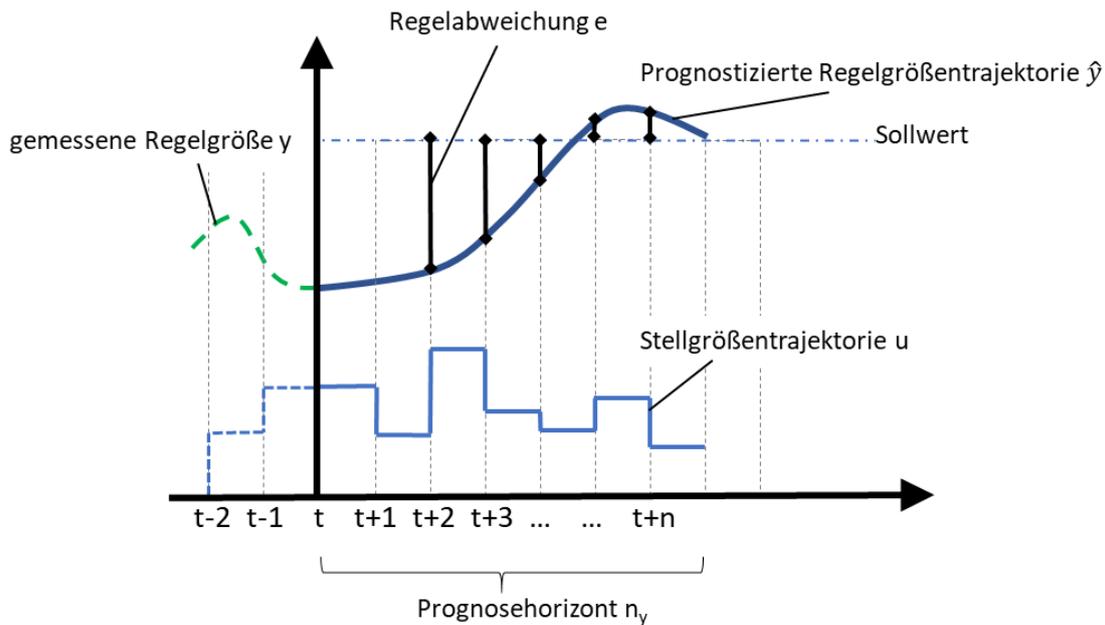


Abbildung 10 Ablauf der modellprädiktiven Regelung bei konstantem Sollwert

Der Entwurf einer modellprädiktiven Regelung besteht aus den folgenden Schritten:

1. Bestimmung eines diskreten Systemmodells für eine Einschrittvorhersage in Abhängigkeit der bekannten Ein- und Ausgangsgrößen in der Form $y(k + 1) = f(y(k), u(k))$.
2. Festlegung eines endlichen Horizonts n_y für die Prädiktion der Ausgangsgröße und eines endlichen Horizonts n_u für die frei wählbaren Stellgrößen.
3. Erweiterung des Systemmodells auf eine Vielschritt-Vorhersage durch rekursives Verwenden der Einschrittvorhersage bis zum Prädiktionshorizont n_y mit frei wählbaren Stellgrößen bis zum Stellhorizont n_u . In der Regel bleibt die Stellgröße nach dem Stellhorizont n_u bis zum Erreichen des Prädiktionshorizont n_y dann konstant, was die Freiheitsgrade des Optimierungsproblems erheblich reduziert.
4. Festlegung von Randbedingungen für die Stell- und Ausgangsgrößen.
5. Bestimmung eines Gütefunktional J zur Bewertung der Ausgangsgrößen und des Stellaufwandes unter Verwendung der Vielschrittvorhersage bis zum Prädiktionshorizont n_y .
6. Auswahl eines Optimierungsverfahren zur Optimierung der Stellgrößen bis zum Prädiktionshorizont n_u durch Minimierung des Gütefunktional J unter Berücksichtigung der Randbedingungen.

Anstelle eines konstanten Sollwertes r kann auch eine Referenztrajektorie verwendet werden. Ziel der modellprädiktiven Regelung ist es dann, diejenige Stellgrößenfolge (Stellgrößentrajektorie) $u(k), u(k + 1), \dots, u(k + n - 1)$ zu finden, bei der die prognostizierte Regelgrößentrajektorie $\hat{y}(k + 1), \hat{y}(k + 2), \dots, \hat{y}(k + n)$ einer vorgegebenen Referenztrajektorie $w(t)$ folgt. Die Referenztrajektorie approximiert den optimalen Verlauf der zukünftigen Ausgangsgrößenfolgen bei Konvergenz zum Sollwert $r(t)$:

$$\begin{aligned} w(t) &= y(t) \\ w(t + k) &= \alpha \cdot w(t + k - 1) + (1 - \alpha) \cdot r(t + k). \end{aligned} \tag{45}$$

Abbildung 11 verdeutlicht das Prinzip der modellprädiktiven Regelung mit Referenztrajektorie.

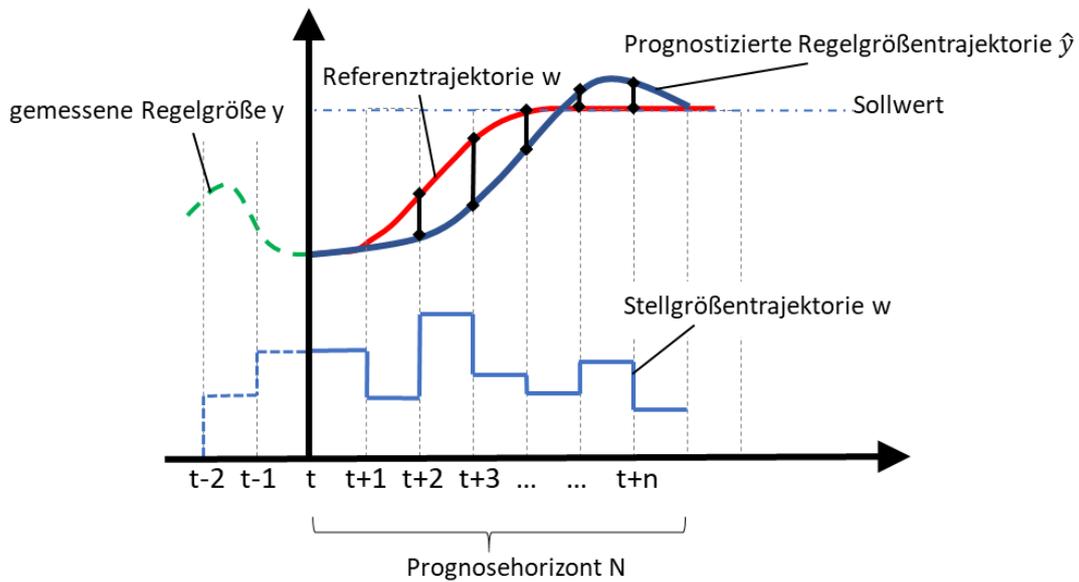


Abbildung 11 Prinzip der modellprädiktiven Regelung mit Referenztrajektorie

Um das Konzept der modellprädiktiven Regelung weiter zu veranschaulichen, wird im Folgenden die Herleitung eines möglichen Verfahrens zur linearen modellprädiktiven Regelung ohne Begrenzungen und mit Begrenzungen sowie nichtlineare modellprädiktive Regelung im Zustandsraum gezeigt.

2.2.1 Lineare modellprädiktive Regelung ohne Begrenzungen

Der Zustand eines Systems lässt sich durch seine Zustandsgrößen mit

$$x(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ x_3(t) \\ x_4(t) \end{bmatrix} \quad (46)$$

beschreiben. Die Änderung des Zustands des Systems kann durch Differentialgleichungen in der Form

$$\dot{x}(t) = f(t, x(t), u(t)) \quad (47)$$

beschrieben werden. Der Ausgang des Systems $y(t)$ ist abhängig vom Zustand des Systems, der Stellgrößen und externen Störgrößen:

$$y(t) = f(x(t), u(t), d(t)). \quad (48)$$

Bei einem linearen zeitinvarianten System lautet die allgemeine Zustandsform (Vektorielle Zustandsform)

$$\dot{x}(t) = Ax(t) + Bu(t) \quad (49)$$

$$y(t) = Cx(t) + d(t). \quad (50)$$

Modellprädiktive Algorithmen verwenden in der Regel zeitdiskrete Modelle mit einer Einschrittvorhersage. Daher müssen die DGLs in der Form

$$x_{k+1} = Ax_k + Bu_k \quad (51)$$

$$y_k = Cx_k + d_k \quad (52)$$

diskretisiert werden. Eine n-Schritt Prädiktion der Zustandsgröße x lautet dementsprechend

$$x_{k+n} = A^n x_k + A^{n-1} Bu_k + A^{n-2} Bu_{k+1} \dots + ABu_{k+n-2} + Bu_{k+n-1}. \quad (53)$$

Zur Prognose der Regelgröße wird für gewöhnlich der Störgrößenterm d_k über den Prädiktionshorizont als konstant angenommen. Hieraus ergibt sich

$$y_{k+1} = Cx_{k+1} + d_{k+1}; \quad d_{k+1} = d_k \quad (54)$$

$$y_{k+n} = CA^n x_k + C(A^{n-1} Bu_k + A^{n-2} Bu_{k+1} \dots + ABu_{k+n-2} + Bu_{k+n-1}) + d_k. \quad (55)$$

Für gewöhnlich kennzeichnet man in der Gleichung auch den Zeitpunkt der Prädiktion. Für eine Prädiktion vom Zeitpunkt k für den Zeitpunkt $k + n$ lauten damit die Gleichungen (53) und (54)

$$x_{k+n|k} = A^n x_k + A^{n-1} Bu_{k|k} + A^{n-2} Bu_{k+1|k} \dots + ABu_{k+n-2|k} + Bu_{k+n-1|k} \quad (56)$$

$$y_{k+n|k} = CA^n x_k + C(A^{n-1} Bu_{k|k} + A^{n-2} Bu_{k+1|k} \dots + ABu_{k+n-2|k} + Bu_{k+n-1|k}) + d_k. \quad (57)$$

Zur Vereinfachung der Darstellung werden die zukünftigen Zustands- und Regelgrößen in vektorieller Schreibweise mit

$$\begin{bmatrix} x_{k+1|k} \\ x_{k+2|k} \\ \vdots \\ x_{k+n|k} \end{bmatrix} = \vec{x}_{k+1} \quad (58)$$

zusammengefasst. Der nach rechts gerichteten Pfeil kennzeichnet hierbei zukünftige Werte. Hiermit lassen sich sämtliche Prädiktionen der Zustandsgrößen (56) bis zum Prognosehorizont n kompakt in Matrix-Notation mit

$$\vec{x}_{k+1} = \begin{bmatrix} Ax_k + Bu_{k|k} \\ A^2 x_k + ABu_{k|k} + Bu_{k+1|k} \\ \vdots \\ A^n x_k + A^{n-1} Bu_{k|k} + A^{n-2} Bu_{k+1|k} \dots + ABu_{k+n-2|k} + Bu_{k+n-1|k} \end{bmatrix} \quad (59)$$

darstellen. Zur weiteren Berechnung werden Zustands- und Stellgrößen getrennt dargestellt:

$$\vec{x}_{k+1} = \begin{bmatrix} Ax_k \\ A^2 x_k \\ \vdots \\ A^n x_k \end{bmatrix} + \begin{bmatrix} Bu_{k|k} \\ ABu_{k|k} + Bu_{k+1|k} \\ \vdots \\ A^{n-1} Bu_{k|k} + A^{n-2} Bu_{k+1|k} \dots + ABu_{k+n-2|k} + Bu_{k+n-1|k} \end{bmatrix}. \quad (60)$$

Analog zu (58) können auch die Stellgrößen vektoriell dargestellt und ausgeklammert werden:

$$\begin{aligned} \vec{x}_{k+1} &= \begin{bmatrix} A \\ A^2 \\ \vdots \\ A^n \end{bmatrix} x_k + \begin{bmatrix} B & 0 & \dots & 0 \\ AB & B & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ A^{n-1}B & A^{n-2}B & \dots & B \end{bmatrix} \begin{bmatrix} u_{k|k} \\ u_{k+1|k} \\ \vdots \\ u_{k+n-1|k} \end{bmatrix} \\ &= \begin{bmatrix} A \\ A^2 \\ \vdots \\ A^n \end{bmatrix} x_k + \begin{bmatrix} B & 0 & \dots & 0 \\ AB & B & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ A^{n-1}B & A^{n-2}B & \dots & B \end{bmatrix} \vec{u}_k. \end{aligned} \quad (61)$$

Aus Gleichung (61) ergibt sich die kompakte Matrixschreibweise

$$\vec{x}_{k+1} = P x_k + H \vec{u}_k. \quad (62)$$

Die Matrizen P und H sind hierbei lediglich von Modellparametern abhängig. Der Zustand der letzten Messung wird durch x_k und die frei wählbaren zukünftigen Stellgrößen sind durch \vec{u}_k repräsentiert. Der Systemausgang und damit der zu prognostizierende Verlauf der Ausgangsgröße lässt sich ähnlich kompakt darstellen, wobei d_k die letzte gemessene Störung darstellt. Diese Störung wird für die nächsten Schritte als konstant angenommen. Hieraus ergibt sich

$$\vec{y}_{k+1} = P x_k + L d_k + H \vec{u}_k. \quad (63)$$

Um im stationären Zustand eine bleibende Regelabweichung zu verhindern, kann der Störgrößenterm d_k auch durch eine Störgrößenschätzung ersetzt werden. Diese Störgrößenschätzung wird dann aus der Differenz der gemessenen Ausgangsgröße y_p und der durch das Modell prognostizierten Ausgangsgröße mit

$$d_m(k+1) = y_p(k) - y_m(k) \quad (64)$$

berechnet. Hierdurch werden Abweichungen durch Störgrößen als auch durch Modellunsicherheiten kompensiert. Alternativ hierzu kann die Regelabweichung im stationären Zustand auch durch die Verwendung der Abweichungen der Zustands-, Stell- und Regelgrößen zum Ruhezustand (deviation variables) verringert werden. Hierfür werden zunächst die Zustands- und Ausgangsgrößen im stationären Zustand, d.h. beim Erreichen des Regelziels betrachtet. Im stationären Zustand bleiben Zustands-, Stell- und Regelgrößen konstant. Dadurch gilt

$$x_{sz} = A x_{sz} + B u_{sz} \quad (65)$$

$$y_{sz} = C x_{sz} + d. \quad (66)$$

Die Gleichungen (65) und (66) ergeben nach Umstellung nach u_{sz} bzw. x_{sz}

$$u_{sz} = B^{-1} x_{sz} [I - A] \quad (67)$$

$$x_{sz} = C^{-1} (y_{sz} - d). \quad (68)$$

Durch Einsetzen von (68) in (67) kann x_{sz} in (67) ersetzt werden. Damit kann der stationäre Zustand der Zustands- und Stellgrößen bei Erreichen des Regelziels in Matrixschreibweise in der Form

$$\begin{bmatrix} x_{sz} \\ u_{sz} \end{bmatrix} = \begin{bmatrix} C & 0 \\ A - I & B \end{bmatrix}^{-1} \begin{bmatrix} y_{sz} - d \\ 0 \end{bmatrix} \quad (69)$$

dargestellt werden. Die Ausgangsgröße im Zielzustand ist hierbei bekannt, da sie dem Regelziel y_{soll} entspricht. Der Zustand der Störgröße d ist unbekannt und muss geschätzt werden.

Die Abweichungen der Zustands-, Stell- und Regelgrößen zum Ruhezustand (\hat{x}_k , \hat{u}_k und \hat{y}_k) ergeben sich damit zu

$$\hat{x}_k = x_k - x_{sz} \quad (70)$$

$$\hat{u}_k = u_k - u_{sz} \quad (71)$$

$$\hat{y}_k = y_k - y_{sz}. \quad (72)$$

Werden Gleichung (51) und (65) in (70) und Gleichung (52) und (66) in (72) und (71) eingesetzt, so ergeben sich die Zustandsgleichungen für die Abweichungen der Zustands-, Stell- und Regelgrößen zum Ruhezustand (deviation variables):

$$\begin{aligned} \hat{x}_{k+1} &= x_{k+1} - x_{sz} \\ &= [Ax_k + Bu_k] - [Ax_{sz} + Bu_{sz}] \\ &= A\hat{x}_k + B\hat{u}_k \end{aligned} \quad (73)$$

$$\begin{aligned} \hat{y}_k &= [Cx_k + d_k] - [Cx_{sz} + d_k] \\ &= C\hat{x}_k. \end{aligned} \quad (74)$$

Die Störgröße ist nun nicht mehr in der Ausgangsgrößengleichung, sondern versteckt in der Zustandsgrößengleichung vorhanden. Die prognostizierte Trajektorie der Abweichungen der Ausgangsgröße zum stationären Zustand bis zum Prognosehorizont lässt sich analog zu (63) in kompakter Notation mit

$$\hat{y}_{k+1} = P\hat{x}_k + H\hat{u}_k \quad (75)$$

darstellen. Da eine Prognose der Ausgangsgrößentrajektorie und nicht der Abweichungen der Ausgangsgröße zum stationären Zustand erforderlich ist, muss Gleichung (75) analog zu (72) umgeformt werden. Hieraus ergibt sich die Prognose der Ausgangsgrößentrajektorie mit

$$y_{k+1} = P\hat{x}_k + H\hat{u}_k + Ly_{sz}. \quad (76)$$

Ziel der modellprädiktiven Regelung ist es, eine optimale Stellgrößentrajektorie zu finden. Die Optimierung erfolgt in der Regel anhand von zwei der drei Kriterien:

- Erreichung des Regelziels y_{soll}
- Minimierung des Energiebedarfs durch Minimierung der energierelevanten Stellgrößen u
- oder Minimierung des Stellaufwandes Δu .

Die Güte der Regelung wird anhand eines Kostenfunktional J definiert. Das zu erreichende Optimum wird hierbei über eine Minimierung dieses Kostenfunktional gesucht. Da Optimierungsprobleme für quadratische Gleichungen besonders effizient zu lösen sind, wird das Kostenfunktional als quadratische Gleichung mit

$$J = x^2 + ax + b \equiv (x - \alpha)^2 + \beta \quad (77)$$

formuliert.

Diese Formulierung bietet 3 wesentliche Vorteile:

1. Energieterme in physikalischen Gleichungen beinhalten meist eine Quadrierung der Zustandsgrößen.
2. Quadratische Terme sind immer positiv.
3. Große Abweichungen vom Regelziel werden im Kostenfunktional stärker bestraft als kleine Abweichungen.

Da sich die Ziele *Erreichung des Regelziels* und *Minimierung des Energiebedarfs* widersprechen, werden zusätzliche Gewichtungparameter λ und μ eingeführt. Nach Überführung der Gütekriterien in die quadratische Form kann z.B. das Gütefunktional der MPC mit

$$J = \sum_{k=1}^n (e_{k+1}^2 + \lambda(u_k)^2) \text{ bzw. } J = \sum_{k=1}^n (e_{k+1}^2 + \mu(\Delta u_k)^2) \quad (78)$$

formuliert werden. Hierbei ist e_k die Regelabweichung der Ausgangsgröße zur Führungsgröße. Die prognostizierte Regelabweichung kann mit

$$e_{k+1} = y_{soll} - y_{k+1}, \quad (79)$$

und der Stellaufwand Δu_k durch die Änderung der Stellgröße mit

$$\Delta u_k = u_k - u_{k-1} \quad (80)$$

berechnet werden. Anstelle der direkten Verwendung der Stellgröße ist es üblich, die Abweichung \hat{u}_k der Stellgröße u_k zum Ruhezustand u_{sz} zu verwenden. Hierdurch wird im Gütefunktional nur der Energieeintrag bestraft, der über die zur Kompensation der Störgrößen benötigten Energie hinausgeht. Des Weiteren können zur Bewertung des Kostenfunktionals unterschiedliche Prädiktionshorizonte für die Regelgröße und die Stellgröße verwendet werden. Da für gewöhnlich das Regelziel nach einer Anzahl n_u von Zeitschritten erreicht wird und danach die Änderung der Stellgröße Δu_k und damit auch \hat{u}_k verschwindet, werden beide Terme nur bis zum Stellhorizont betrachtet. Die Regelgröße hingegen wird bis zum tatsächlichen zu prognostizierenden Prädiktionshorizont n_y , der den Stellhorizont in der Regel überschreitet, betrachtet:

$$J = \sum_{k=1}^{n_y} e_{k+1}^2 + \sum_{k=1}^{n_u} \lambda(u_k - u_{sz})^2 \text{ bzw. } J = \sum_{k=1}^{n_y} e_{k+1}^2 + \sum_{k=1}^{n_u} \mu \Delta u_k^2. \quad (81)$$

Das Gütefunktional lässt sich in kompakter vektorieller Schreibweise durch Verwendung der Abweichungen der Zustands-, Stell- und Regelgrößen zum Ruhezustand gemäß (70)-(72) darstellen:

$$J = e_{\rightarrow k+1}^T Q e_{\rightarrow k+1} + (\hat{u}_k)^T R (\hat{u}_k) \quad (82)$$

Die Verwendung der Gewichtungsmatrizen Q und R bietet den Vorteil, dass zukünftig weiter entfernt liegende Abweichungen stärker oder schwächer gewichtet werden können wenn Q oder R nicht als Einheitsmatrizen verwendet werden, um z.B. am Anfang stärkere Abweichungen zuzulassen.

Der Verlauf der Regelabweichung \vec{e} bis zum Prognosehorizont entspricht mit

$$\vec{e} = \vec{\hat{y}}_{k+1} = P\hat{x}_k + H\vec{\hat{u}}_k \quad (83)$$

den Abweichungen der Ausgangsgröße zum stationären Zustand bis zum Prognosehorizont.

Hieraus ergibt sich das Gütefunktional zu

$$J = [P\hat{x}_k + H\vec{\hat{u}}_k]^T Q[P\hat{x}_k + H\vec{\hat{u}}_k] + (\vec{\hat{u}}_k)^T R(\vec{\hat{u}}_k). \quad (84)$$

Exkurs Ableitungsregeln:

$$\text{grad}(a^T x) = a \quad (85)$$

$$\text{grad}(x^T S x) = S x + S^T x = [S + S^T] x. \quad (86)$$

Zur Bestimmung des Optimums wird der Gradient des Gütefunktionals zu Null gesetzt:

$$\text{grad}(J) = 0 \Rightarrow 2[H^T Q H + R] \vec{\hat{u}}_k + 2H^T Q P \hat{x}_k = 0. \quad (87)$$

Die Umstellung nach $\vec{\hat{u}}_k$ ergibt das Kontrollgesetz für die Stellgrößenänderungstrajektorie

$$\vec{\hat{u}}_k = -[H^T Q H + R]^{-1} H^T Q P \hat{x}_k. \quad (88)$$

In der modellprädiktiven Regelung wird nur der erste Wert der berechneten optimalen Stellgrößen-trajektorie verwendet, hiernach das Zeitfenster der Prognose verschoben (receding horizon) und die Berechnung für den aktuellen Prognosehorizont erneut durchgeführt. Daher wird die Stellgrößen-trajektorie mit einem transponierten Vektor multipliziert:

$$\hat{u}_k = -E_1^T [H^T Q H + R]^{-1} H^T Q P \hat{x}_k. \quad (89)$$

Da der aktuelle Wert der Stellgröße, und nicht der Wert der Abweichung der Stellgröße zum Zustand im Ruhezustand notwendig ist, müssen $\vec{\hat{u}}_k$ und \hat{x}_k durch (70) und (71) substituiert werden. Daraus ergibt sich das Regelgesetz für die optimale nächste Stellgröße u_k

$$u_k - u_{sz} = -E_1^T [H^T Q H + R]^{-1} H^T Q P [x_k - x_{sz}]. \quad (90)$$

$$= -K[x_k - x_{sz}]$$

Um die jeweils nächste Stellgröße u_k zu berechnen, müssen in jedem Prognoseschritt u_{sz} und x_{sz} gemäß (67) und (68) aus der aktuellen Störgrößenschätzung d_k gemäß (64) neu geschätzt werden.

Hieraus wird offensichtlich, dass eine schwache Schätzung der Störgrößen durch den Beobachter und des Modells der Zustandsgrößen (51) zu unbefriedigendem Reglerverhalten führt.

2.2.2 Lineare modellprädiktive Regelung mit Begrenzungen

Aus Systemanforderungen, wie z.B. in Kapitel 3.2 für Kfz-Klimaanlagen erläutert, oder aber auch aus sicherheitstechnischen und konstruktiven Gründen können Begrenzungen für Zustands- und Ausgangsgrößen eines Systems erforderlich sein, die in der Regelung berücksichtigt werden müssen. Des Weiteren unterliegen auch Stellgrößen aufgrund des begrenzten Arbeitsbereichs der Aktoren

definierten Beschränkungen. Dies können ökonomische Gründe, wie z.B. dem COP eines Klimakompressors oder auch schlicht die maximal mögliche Leistung eines Aggregats sein. Auch die Änderung einer Stellgröße Δu kann einer Begrenzung unterliegen, da z.B. die mögliche Bewegung eines Aktors pro Zeitschritt begrenzt ist. Die Beschränkungen können durch lineare Ungleichungen in der Form

$$u_{min} \leq u_k \leq u_{max} \quad (91)$$

$$\Delta u_{min} \leq u_{k+1} - u_k \leq \Delta u_{max} \quad (92)$$

$$y_{min} \leq y_k \leq y_{max} \quad (93)$$

$$x_{min} \leq x_k \leq x_{max} \quad (94)$$

beschrieben werden. Die Begrenzungen müssen für jeden prognostizierten Schritt eingehalten werden. Dies wird in kompakter vektorieller Form mit

$$\begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \\ -1 & 0 & \cdots & 0 \\ 0 & -1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & -1 \end{bmatrix} \begin{bmatrix} \Delta u_k \\ \Delta u_{k+1} \\ \vdots \\ \Delta u_{k+n_u-1} \end{bmatrix} \leq \begin{bmatrix} \Delta u_{max} \\ \Delta u_{max} \\ \vdots \\ \Delta u_{max} \\ -\Delta u_{min} \\ -\Delta u_{min} \\ \vdots \\ -\Delta u_{min} \end{bmatrix} \quad (95)$$

$C_{\Delta u} \quad \Delta u_k \leq d_{\Delta u}$

dargestellt. Analog kann die Beschränkung der Stellgröße in der Form

$$C_u \quad u_k \leq d_u \quad (96)$$

definiert werden. Die Trajektorie der Stellgröße lässt sich, durch den Wert der ersten Stellgröße und den folgenden Änderungen mit

$$\begin{bmatrix} u_k \\ u_{k+1} \\ \vdots \\ u_{k+n_u-1} \end{bmatrix} = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 1 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \cdots & 0 \\ 1 & 1 & \cdots & 0 \end{bmatrix} \begin{bmatrix} \Delta u_k \\ \Delta u_{k+1} \\ \vdots \\ \Delta u_{k+n_u-1} \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} u_{k-1} \quad (97)$$

$\underset{\rightarrow}{u_k} = E \underset{\rightarrow}{\Delta u_k} + L u_{k-1}$

darstellen. Die Umstellung nach Δu_k ergibt

$$\Delta u_k = E^{-1} [u_k - L u_{k-1}] \quad (98)$$

$$C_{\Delta u} \quad \Delta u_k \leq d_{\Delta u}$$

Durch Einsetzen von (97) in (96) lassen sich die Randbedingungen für u und Δu in kompakter Form mit

$$\begin{bmatrix} C_{\Delta u} E^{-1} \\ C_u \end{bmatrix} \underset{\rightarrow}{u_k} + \begin{bmatrix} -E^{-1} L \\ 0 \end{bmatrix} \underset{\rightarrow}{u_{k-1}} \leq \begin{bmatrix} d_{\Delta u} \\ d_u \end{bmatrix} \quad (99)$$

darstellen. Wird im Gütefunktional Δu_k verwendet, muss (97) in (96) eingesetzt werden.

Analog dazu können die Beschränkungen der Zustandsgrößen und Ausgangsgrößen kompakt in der Form

$$C_x \quad \underline{x}_k \leq d_x \quad (100)$$

$$C_y \quad \underline{y}_k \leq d_y \quad (101)$$

dargestellt werden. Analog hierzu lässt sich (99) durch Einsetzen der Prädiktionen der Zustandsgrößen (62) und der Ausgangsgrößen (63) in (100) und (101) als kompakte Form für sämtliche Beschränkungen erweitern:

$$\begin{bmatrix} C_{\Delta u} E^{-1} \\ C_u \\ C_x H \\ C_y H \end{bmatrix} \underline{u}_k + \begin{bmatrix} E^{-1} L \\ 0 \\ 0 \\ 0 \end{bmatrix} u_{k-1} + \begin{bmatrix} 0 \\ 0 \\ C_x P \\ C_y P + L d_k \end{bmatrix} x_k \leq \begin{bmatrix} d_{\Delta u} \\ d_u \\ d_x \\ d_y \end{bmatrix}. \quad (102)$$

Nach Umstellung ergeben sich die Randbedingungen des Regelgesetzes zu

$$\begin{bmatrix} C_{\Delta u} E^{-1} \\ C_u \\ C_x H \\ C_y H \end{bmatrix} \underline{u}_k \leq \begin{bmatrix} d_{\Delta u} \\ d_u \\ d_x \\ d_y \end{bmatrix} - \begin{bmatrix} E^{-1} L \\ 0 \\ 0 \\ 0 \end{bmatrix} u_{k-1} + \begin{bmatrix} 0 \\ 0 \\ C_x P \\ C_y P + L d_k \end{bmatrix} x_k \quad (103)$$

$$C \quad \underline{u}_k \leq d.$$

Die Matrix C ist hierbei konstant und die Matrix d muss in jedem Prognoseschritt durch die Messung der aktuellen Zustandsgrößen, durch den letzten Wert der Stellgrößen und die aktuellen Störgrößen-schätzung als Anfangswert aktualisiert werden.

Analog zu 2.2.1 wird auch bei der linearen modellprädiktiven Regelung mit Begrenzungen ein Kostenfunktional durch die Prädiktion gebildet:

$$J = [r - P x_k - L d_k - H \underline{u}_k]^T Q [r - P x_k - L d_k - H \underline{u}_k] + (\underline{u}_k - u_{sz})^T R (\underline{u}_k - u_{sz}). \quad (104)$$

Durch Ausmultiplikation, Zusammenfassung und Streichung der Konstanten kann (104) in die quadratische Form

$$J = [-2r^T Q H + 2P x_k^T Q H + 2L d_k^T Q H - 2u_{sz}^T R] \underline{u}_k + \underline{u}_k^T [H^T Q H + R] \underline{u}_k \quad (105)$$

$$J = \begin{matrix} a & & & \\ & \underline{u}_k + \underline{u}_k^T & S & \\ & & & \underline{u}_k \end{matrix}$$

gemäß (77) überführt werden. Hierdurch ergibt sich das vollständige quadratische Optimierungsproblem für die allgemeine Zustandsform mit

$$\begin{matrix} \min \\ \underline{u}_k \\ \rightarrow \end{matrix} a \underline{u}_k + \underline{u}_k^T S \underline{u}_k \quad (106)$$

$$\text{u.B.v. } C \underline{u}_k \leq d.$$

Diese Form des Optimierungsproblems kann bei Problemen mit beschränkter Komplexität durch Formulierung von Karush-Kuhn-Tucker-Bedingungen, Ermittlung der Karush-Kuhn-Tucker-Punkte und Prüfung der Regularitätsbedingungen gelöst werden. Eine ausführliche Beschreibung des Verfahrens erfolgt in [77]. Für Probleme höherer Ordnung ist diese Form des Optimierungsproblems aufgrund der Komplexität nicht mehr analytisch lösbar und muss numerisch gelöst werden. Üblich sind hierbei QP-Optimierungsverfahren wie z.B. das Innere-Punkte-Verfahren oder das Trust-Region-Verfahren. Diese Verfahren werden in [80], [81] und [82] näher beschrieben und können in Softwareanwendungen wie z.B. Matlab mit quadprog⁸ und in Programmiersprachen wie C mit qld⁹ als bereitgestellte Funktionen verwendet werden.

2.2.3 Nichtlineare modellprädiktive Regelung mit Begrenzungen

Wie in 2.1.3 beschrieben, ist für eine adäquate Abbildung des komplexen thermischen Verhaltens ein nichtlineares Modell erforderlich. Der in den Kapiteln 2.2.1 und 2.2.2 beschriebene Lösungsansatz ist hierfür nicht mehr anwendbar, da das resultierende nichtlineare dynamische Optimierungsproblem nicht mehr in quadratischer Form vorliegt und sich auch nicht nach den Stellgrößen auflösen lässt. Um das Grundprinzip der modellprädiktiven Regelung dennoch auf nichtlineare Systeme anzuwenden werden in der Literatur verschiedene Lösungsansätze diskutiert [6]. Prinzipiell lassen sich diese Ansätze in Verfahren unterscheiden, die ein linearisiertes Ersatzmodell verwenden und Verfahren die das nichtlineare Prozessmodell direkt verwenden.

Bei der ersten Art von Verfahren erfolgt eine Linearisierung des Modells z.B. durch die Verwendung einer nichtlinearen Variablentransformation und Anwendung des ursprünglichen linearen modellprädiktiven Verfahrens auf das lineare Ersatzsystem. Problematisch ist hierbei, dass eine geeignete Transformationsbeziehung für die Vorwärts- und Rückwärtstransformation existieren muss, die das Systemverhalten für den gesamten Wertebereich der Zustands- und Stellgrößen adäquat abbildet. Dieses Problem kann unter Umständen durch die Verwendung von multiplen linearen Teilmodellen umgangen werden. Der Gesamtsystemausgang wird hierbei durch Addition der unterschiedlich gewichteten Ausgänge der Teilmodelle berechnet. Die Gewichtung der Ausgänge wird nach jeweiliger Vorhersagegüte der Teilmodelle im Regelungsprozess angepasst. Bei hoher Dynamik der Eingangsgrößen, wie im vorliegenden Problemfall, geraten diese Verfahren an ihre Grenze.

Die zweite Art von Verfahren wird auch als NMPC (Nonlinear Model Predictive Control) bezeichnet. Diese unterscheiden sich in direkte und indirekte Verfahren, sowie in sequentielle und simultane Verfahren. Eine zusammenfassende Beschreibung dieser Verfahren ist in [76] zu finden. Die indirekten Verfahren leiten ein Randwertproblem aus den notwendigen Bedingungen erster Ordnung ab und optimieren die Stellgrößentrajektorie durch das Lösen dieses Randwertproblems. Man spricht hierbei von einer „first optimize, then discretize“-Strategie. Direkte Verfahren hingegen transformieren das dynamische Optimierungsproblem durch Diskretisierung in ein finites statisches Ersatzproblem und lösen dieses durch ein numerisches Verfahren [77]. Man spricht hierbei von einer „first discretize, then optimize“-Strategie.

Das meist verbreitete indirekte Verfahren ist das indirekte Schießverfahren (Single Shooting Method). Hierbei wird gemäß dem Pontryaginschen Maximumsprinzip eine Hamilton-Funktion bzw. eine erweiterte Hamilton-Funktion bei Ungleichheitsbedingungen formuliert und daraus die Optimalitäts-

⁸ Mathworks: Optimization Toolbox Users's Guide. Mathworks, 2002

⁹ K. Schittkowski: Solution of Quadratic Programming Problems. Mathematisches Institut, Universität Bayreuth.

bedingungen abgeleitet. Die Hamilton-Funktion besteht aus der Lagrange-Funktion sowie dem Produkt aus Lagrange-Multiplikatoren und dem Prozessmodell. Die notwendigen Optimalitätsbedingungen werden aus den partiellen Ableitungen der Hamiltonfunktion nach den Steuer- und Zustandsgrößen sowie der Lagrange-Multiplikatoren, welche auch als Kozustände bezeichnet werden, gebildet. Aus den notwendigen Optimalitätsbedingungen und den Randbedingungen der Zustandsgrößen und Lagrange-Multiplikatoren erhält man ein Randwertproblem, dessen Lösung die optimale Trajektorie der Stellgrößen darstellt, wenn die notwendige zweite Optimalitätsbedingung¹⁰ erfüllt ist. Im Falle der stetigen Differenzierbarkeit der Funktion kann dies durch ein Newton- oder Quasi-Newtonverfahren erfolgen. Falls eine exakte Lösung nicht oder nur sehr ineffizient möglich ist, können Einschrittverfahren wie z.B. das Runge-Kutta-Verfahren oder auch Mehrschrittverfahren wie die Adams-Bashforth-Methode verwendet werden. Problematisch ist, dass die Anfangsrandbedingung des Lagrange-Operators zu Beginn des Verfahrens geschätzt werden muss. Durch ein iteratives Vorgehen des Verfahrens wird dieser Schätzwert schrittweise verbessert, so dass sukzessiv die Erfüllung der Randbedingung ebenfalls verbessert wird. Reagiert die resultierende Trajektorie sehr sensibel auf kleine Änderungen des Anfangszustands oder ist die Funktion unstetig, sind Single-Shooting-Verfahren aufgrund der auftretenden Ungenauigkeiten nicht geeignet. Weitere indirekte Verfahren sind Gradienten-Verfahren und Verfahren der Quasilinearisierung [77].

Zu den direkten Verfahren zählen das direkte Einzelschießverfahren (Direct Single Shooting), das Kollaktionsverfahren (Collocation) und das direkte Mehrfachschießverfahren (Direct Multiple Shooting). Bei den direkten Verfahren wird das dynamische Optimierungsproblem in ein statisches Optimierungsproblem umgewandelt und dann die Lösung numerisch berechnet. Beim direkten Einzelschießverfahren wird die Steuertrajektorie zwischen diskreten Zeitpunkten auf einem Gitter mit festen Zeitschritten approximiert. Eine mögliche Approximation ist eine stückweise konstante Steuertrajektorie zwischen den Zeitschritten:

$$u(t) := \varphi_i(t, u_i) = (u_0, u_1, u_2, \dots, u_{n-1}). \quad (107)$$

Mit Hilfe dieser Approximation wird durch Integration der Differentialgleichung über den Prädiktionshorizont die Gleichung der Zustandstrajektorie berechnet, welche dann nur noch von der Approximation der Stellgrößen abhängig ist. Die Ungleichheitsbedingungen werden ebenfalls an den Gitterpunkten diskretisiert. Man erhält ein finites nichtlineares Optimierungsproblem:

$$\begin{aligned} \underbrace{\min}_u f(u) \\ \text{u.B.v. } h(u) = 0, \quad g(u) \geq 0. \end{aligned} \quad (108)$$

Das „ursprüngliche“ Gütefunktional wird durch den ersten Term repräsentiert, der zweite Term repräsentiert die Gleichheitsbedingungen und der dritte Term die Ungleichheitsbedingungen. Dieses Optimierungsproblem kann durch ein SQP-Verfahren (Sequential Quadratic Programming) gelöst werden. Eine ausführliche Beschreibung des SQP-Verfahrens findet sich in [83] und [78].

Im ersten Schritt wird eine Lagrange-Funktion formuliert:

$$\mathcal{L}(u, \lambda, \mu) = f(u) + \lambda^T h(u) + \mu^T g(u) \quad (109)$$

¹⁰ Die 2-fache Ableitung der Hamiltonfunktion nach den Steuergrößen muss positiv definit sein

Die Lagrange-Multiplikatoren λ und μ sind Vektoren aus skalaren Variablen zur Einbindung der Gleichheits- und Ungleichheitsbedingungen in das Gütefunktional. Die notwendige Bedingung für eine optimale Steuertrajektorie u^* sind wieder die KKT-Bedingungen. Das bedeutet, dass bei u^* Lagrange-Multiplikatoren λ^* und μ^* existieren, welche die folgenden Bedingungen erfüllen:

$$\nabla_u \mathcal{L}(u^*, \lambda^*, \mu^*) = 0 \quad (110)$$

$$h(u^*) = 0 \quad (111)$$

$$g(u^*) \geq 0 \quad (112)$$

$$\mu^* \geq 0 \quad (113)$$

$$g(u^*)^T \mu^* = 0. \quad (114)$$

Das SQP-Verfahren bestimmt die optimale Steuertrajektorie und die zugehörigen Lagrange-Multiplikatoren iterativ, ausgehend von initial zulässigen aber nicht optimalen Startwerten u_0, λ_0, μ_0 . In jedem Iterationsschritt wird eine verbesserte Steuertrajektorie durch einen Korrekturwert Δu_k berechnet:

$$u_{k+1} = u_k + \Delta u_k. \quad (115)$$

Der Korrekturwert Δu_k wird durch das Lösen eines quadratischen Hilfsproblems berechnet. Das Hilfsproblem wird durch eine Taylorreihenentwicklung der Lagrange-Funktion um u_k konstruiert und hat die Form

$$\begin{aligned} \min_{\Delta u} \quad & \frac{1}{2} \Delta u^T H_k \Delta u + \nabla_u f(u_k)^T \Delta u \\ \text{u.B.v.} \quad & \begin{cases} h(u_k) + \nabla_u h(u_k)^T \Delta u = 0 \\ g(u_k) + \nabla_u g(u_k)^T \Delta u \geq 0. \end{cases} \end{aligned} \quad (116)$$

Die Matrix H_k ist die Hesse-Matrix der Lagrange-Funktion (109):

$$H_k = \nabla_{uu}^2 \mathcal{L}(u, \lambda, \mu). \quad (117)$$

Die Terme $\nabla_u h(u_k)^T$ und $\nabla_u g(u_k)^T$ in den Nebenbedingungen des Hilfsproblems sind die Jacobi-Matrizen der Gleichheits- und Ungleichheitsbedingungen des Hauptproblems. Das quadratische Hilfsproblem wird wie in 2.2.2 durch ein Innere-Punkte-Verfahren oder das Trust-Region-Verfahren gelöst. Dabei erhält man einen KKT-Punkt $(\Delta u_k, \lambda_k^{QP}, \mu_k^{QP})$ des quadratischen Hilfsproblems. Der ermittelte Korrekturwert Δu_k wird zur Berechnung der verbesserten Steuertrajektorie u_{k+1} und die ermittelten Lagrange-Multiplikatoren des Hilfsproblems zum Update der Lagrange-Multiplikatoren des Hauptproblems verwendet:

$$\lambda_{k+1} = \lambda_k^{QP} \quad (118)$$

$$\mu_{k+1} = \mu_k^{QP}. \quad (119)$$

Erfüllt der ermittelte KKT-Punkt $(u_{k+1}, \lambda_{k+1}, \mu_{k+1})$ die Gleichungen (110)-(114), ist er ein KKT-Punkt des Hauptproblems. Damit ist u_{k+1} optimal und das Verfahren wird abgebrochen. Falls nicht, wird das

QP-Verfahren mit dem aktualisierten KKT-Punkt und der aktualisierten Hessematrix H_{k+1} erneut durchgeführt.

Ist die Differentialgleichung schlecht konditioniert oder sind die Startwerte schlecht gewählt, so liefert die Integration über sämtliche Intervalle bis zum Prädiktionshorizont mit einer approximierten Steuertrajektorie nur ein ungenaues Ergebnis [77]. Deshalb wird in der Praxis anstelle des sequentiellen Einzelschießverfahrens in der Regel ein simultanes direktes Mehrfachschießverfahren verwendet, bei dem die Integration der Differentialgleichung nur auf einem Teilintervall erfolgt. Das direkte Mehrfachschießverfahren wird sehr ausführlich in [79] beschrieben. Wie beim Einzelschießverfahren wird die Steuertrajektorie auf den Teilintervallen stückweise konstant approximiert. Die Startwerte der Zustandsgrößen auf jedem Teilintervall werden als zusätzliche Parameter s in das Optimierungsproblem integriert. Damit lauten die freien Parameter des Optimierungsproblems

$$c = [u_0^T \ u_1^T \ \dots \ u_{n-1}^T \ s_1^T \ \dots \ s_{n-1}^T]^T. \quad (120)$$

Beim Mehrfachschießverfahren erfolgt die Integration der Differentialgleichung über jedes einzelne Teilintervall, ausgehend von einer initialen Startlösung für c :

$$\dot{x}_i(t) = f(x_i(t), u_i) \quad t \in [t_i, t_{i+1}] \quad (121)$$

$$x_i(t_i) = s_i. \quad (122)$$

Durch die Lösung der Differentialgleichung (121) mit der Anfangsbedingung (122) erhält man jeweils als Teillösung die Gleichungen der Zustandstrajektorie $x_i(t; s_i, u_i)$ ¹¹. Die Berechnung der Güte auf einem Intervall erfolgt durch die Integration des Gütefunktional Φ über die Intervallgrenzen:

$$J_i(s_i, u_i) = \int_{t_i}^{t_{i+1}} \Phi(x_i(t; s_i, u_i), u_i) dt. \quad (123)$$

Das Gütefunktional ist dabei abhängig von der Lösung von (121) sowie der gewählten Approximation der Steuertrajektorie (107). Um (120) und (121) simultan zu lösen, wird eine zusätzlich skalare Variable

$$z(t) = \int_{t_i}^{t_{i+1}} \Phi(t, x_i(t; s_i, u_i), u_i) dt \quad (124)$$

eingeführt. Hiermit kann das Anfangswertproblem

$$\begin{pmatrix} \dot{z} \\ \dot{x} \end{pmatrix} = \begin{pmatrix} \Phi(t, x, u) \\ f(t, x, u) \end{pmatrix}, \quad \begin{pmatrix} z(t_j) \\ x(t_j) \end{pmatrix} = \begin{pmatrix} 0 \\ s_j \end{pmatrix} \quad (125)$$

definiert werden. Somit ist die Teilgüte auf einem Intervall identisch mit der Lösung von (123) für dieses Intervall:

$$J_i(s_i, u_i) \equiv z(t_{j+1}; s_j, q_j), \quad i = 0, 1, \dots, n - 1. \quad (126)$$

¹¹ Die zusätzlichen Argumente hinter dem Semikolon drücken die Abhängigkeit der Teilstücktrajektorie vom Initialwert der Zustandsgröße und den Steuergrößen aus.

Um die Stetigkeit der Zustandsgrößen über sämtliche Teilintervalle zu gewährleisten, werden zusätzliche Bedingungen für die Zustandsgrößen an den Rändern der Intervalle

$$h(c) = \begin{pmatrix} x_1(t_1; s_0, u_0) - s_1 \\ x_2(t_2; s_1, u_1) - s_2 \\ \vdots \\ x_n(t_n; s_{n-1}, u_{n-1}) - s_n \\ r_b(s_n) \end{pmatrix} = 0 \quad (127)$$

eingeführt. Aus der Summe der Teilgüten und den erweiterten Gleichheitsbedingungen kann das Optimierungsproblem für die freien Parameter aus (120) formuliert werden:

$$\underbrace{\min}_c J(c) = \sum_{i=0}^{n-1} J_i(s_i, u_i) \quad (128)$$

$$h_i(s_i, s_{i+1}, u_i) := x_i(t_{i+1}; s_i, u_i) - s_{i+1} = 0 \quad (129)$$

$$\text{u.B.v.} \quad h_n(s_n) := r_b(s_n) = 0 \quad (130)$$

$$g_i(u_i) \geq 0. \quad (131)$$

Die Lösung des Optimierungsproblems erfolgt, analog zum direkten Einzelschießverfahren, mit dem SQP-Verfahren. So wird wieder die Lagrange-Funktion

$$\mathcal{L}(c, \lambda, \mu) = J(c) + \lambda^T h(c) + \mu^T g(c) \quad (132)$$

formuliert. In jedem Iterationsschritt wird der Vektor der freien Parameter c durch einen Korrekturwert Δc_k , der sich wiederum aus der Suchrichtung p_k und einem Relaxationsfaktor α_k zusammensetzt, berechnet:

$$c_{k+1} = c_k + \Delta c_k = c_k + \alpha_k p_k. \quad (133)$$

Wie beim direkten Einzelschießverfahren wird durch eine Taylorreihenentwicklung aus der Lagrange-Funktion das quadratische Hilfsproblem

$$\begin{aligned} \underbrace{\min}_p \quad & \frac{1}{2} p^T H_k p + \nabla_u J(c_k)^T p \\ \text{u.B.v.} \quad & \begin{cases} h(c_k) + \nabla_c h(c_k)^T p = 0 \\ g(c_k) + \nabla_c g(c_k)^T p \geq 0 \end{cases} \\ & \frac{1}{2} p^T \nabla_{uu}^2 \mathcal{L}(c, \lambda, \mu)_k p + \nabla_u J(c_k)^T p \end{aligned} \quad (134)$$

entwickelt. Die Matrix H_k ist die Hesse-Matrix der Lagrange-Funktion (109)

$$H_k = \nabla_{uu}^2 \mathcal{L}(c, \lambda, \mu). \quad (135)$$

Hierbei erhält man einen KKT-Punkt $(\Delta c_k, \lambda_k^{QP}, \mu_k^{QP})$ des quadratischen Hilfsproblems. Analog zum direkten Einfachschießverfahren werden wieder die KKT Bedingungen des Hauptproblems überprüft:

$$\nabla_u \mathcal{L}(c_{k+1}, \lambda^{QP}, \mu^{QP}) = 0 \quad (136)$$

$$\begin{aligned} \nabla_{cc}^2 \mathcal{L}(c_{k+1}, \lambda^{QP}, \mu^{QP}) p_k + \nabla_c J(c_k) + \nabla_c h(c_k)^T \lambda^{QP} + \nabla_c g(c_k)^T \mu^{QP} &= 0 \\ h(c_k) + \nabla_u h(c_k)^T p_k &= 0 \end{aligned} \quad (137)$$

$$g(c_k) + \nabla_u g(c_k)^T p_k \geq 0 \quad (138)$$

$$\mu^{QP} \geq 0 \quad (139)$$

$$(g(c_k) + \nabla_u g(c_k)^T p_k)^T \mu^{QP} = 0. \quad (140)$$

Erfüllt der ermittelte KKT-Punkt die Gleichungen (110)-(114), ist er ein KKT-Punkt des Hauptproblems. Damit ist c_{k+1} optimal und das Verfahren wird abgebrochen. Falls nicht wird das QP-Verfahren mit dem aktualisierten KKT-Punkt und aktualisierter Hessematrix H_{k+1} erneut durchgeführt. Die notwendige Berechnung der aktuellen Hessematrix stellt rechentechnisch den größten Aufwand dar. Daher werden in der Regel die Hessematrizen in jedem Iterationschritt nicht neu berechnet, sondern mit einem Update-Verfahren approximiert. Übliche Verfahren hierfür sind das Broyden's Update, das Davidon-Fletcher-Powell Update (DFP) oder das Broyde-Fletcher-Goldfarb-Shanno Update (BFGS). Eine weitere übliche Maßnahme zur Verringerung der Rechenzeit, ist die Schätzung von Startlösungen durch Verwendung der Lösungen aus dem letzten Abtastintervall (Initial Value Embedding).

Eine softwaretechnische Umsetzung für den realen Einsatz des direkten Mehrfachschießverfahren zur numerischen Lösung von Optimalsteuerungsproblemen existiert z.B. mit dem Softwarepaket MUCSOD-II, basierend auf den Arbeiten von Diehl, Plitt, Bock, Leineweber, Schäfer und Jost [84].

3 Fahrzeugklimatisierung

3.1 Entwicklungsmethodik

Die Entwicklung von Regelfunktionen zur Einstellung von Luftfeuchtigkeit, Luftverteilung und Lufttemperatur in Kraftfahrzeugen durch Fahrzeugklimaanlagen erfolgt im Rahmen von definierten Entwicklungsprozessen. In der Automobilindustrie stellen diese Entwicklungsprozesse einen Teil eines ganzheitlichen Produktentstehungsprozesses (PEP) des Gesamtsystems Fahrzeug dar. Ein Produktentstehungsprozess definiert die einzelnen Arbeitsschritte von einer Produktidee bis zum fertigen Produkt [85]. In den Produktentstehungsprozess sind sowohl die Organisation des Automobilherstellers (OEM, Original Equipment Manufacturer) als auch die Organisationen der Zulieferer involviert. In der Automobilindustrie haben sich je nach OEM verschiedene herstellereigenspezifische Produktentstehungsprozesse¹² für das Gesamtsystem etabliert. Dies ist in der unterschiedlichen Kompetenzstruktur und der Aufteilung zwischen Eigen- und Fremdleistung begründet [86]. Der Produktentstehungsprozess erstreckt sich je nach Hersteller vom Projektanstoß bis zum Start-of-Production (SOP) über einen Zeitraum von 3 bis 5 Jahren [87]. Im Vergleich zu anderen Industriebereichen haben die PEPs der OEMs in der Automobilindustrie aber eine Vielzahl an Gemeinsamkeiten. Das Vorgehen richtet sich in der Regel nach einem Stage-Gate-Modell nach Cooper [88] und nach dem Prozess-Referenz- und Prozess-Assessment-Modell Automotive SPICE [89]. Der Gesamtprozess wird in Phasen, sogenannte Stages, unterteilt. In den einzelnen Phasen erfolgt eine parallele Durchführung der Aktivitäten der betroffenen Abteilungen der OEMs und Zulieferer. Hierbei findet das Prinzip der Kapselung durch Unterteilung in fachliche Kompetenzbereiche, die ihren Ursprung in der mechanischen Modularisierung der Fahrzeuge haben, Anwendung [90]. Für vollelektrifizierte Fahrzeuge ist z.B. die Aufteilung entsprechend der fachspezifischen Fahrzeugdomänen in Fahrzeugsubsysteme wie Antriebsstrang, Fahrwerk (Chassis), Safety, Infotainment, Bordnetz und Karosserie (Body) üblich [90]. Die Entwicklung von Regelfunktionen der Heizungs- und Klimatisierungssteuerung, ist üblicherweise der Entwicklung des Ausstattungsmerkmals (Feature) Klimatisierung zugeordnet. Das Feature Klimatisierung wiederum ist üblicherweise neben anderen Features wie Fensterheber, Sitz- und Spiegelverstellung, Scheibenwischer und Zentralverriegelung der Fahrzeugdomäne Karosserie zugeordnet. Der Gesamtprozess wie auch die einzelnen Phasen und deren Teilprozesse werden über Projektmeilensteine, sogenannte Gateways bzw. Quality Gates, abgesichert und gesteuert [85].

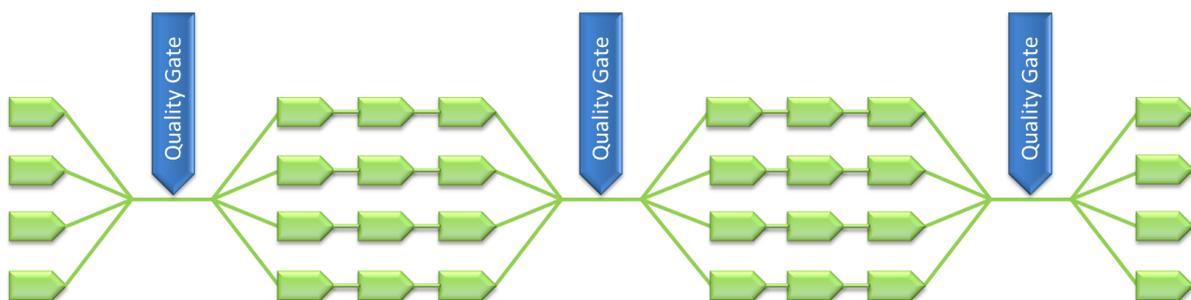


Abbildung 12 Quality Gates im Produktentstehungsprozess [91]

Um die Produktentwicklung möglichst effizient und effektiv zu gestalten, wird in der Automobilindustrie häufig die Strategie des Concurrent bzw. Simultaneous Engineering eingesetzt. Durch die zeitliche Überlappung von traditionell nacheinander folgenden Arbeitsabläufen sollen dabei der Einsatz und die

¹² In einigen Unternehmen wird hierfür synonym der Begriff Produktentwicklungsprozess verwendet.

Verteilung der vorhandenen Ressourcen optimiert werden. Zum Abschluss einer (Teil-)Entwicklungsphase stellen dabei die betroffenen Abteilungen des OEMs bzw. die Lieferanten ein sogenanntes Muster zur Verfügung. Muster stellen dabei nicht fertige Produkte, sondern die zunehmende Konkretisierung zukünftiger Produkte dar [92]. Für jedes Muster wird ein isolierter Akzeptanztest auf Basis von Spezifikationen durchgeführt. Darauf aufbauend erfolgt die Integration in ein Muster einer höheren Abstraktionsebene als Produkt des übergeordneten Entwicklungsprozesses [85]. Über die Gateways werden die parallelen Aktivitäten der unterschiedlichen Fahrzeugdomänen, Features und deren Teilentwicklungsprozesse innerhalb einer Phase zusammengeführt (vgl. Abbildung 12). In [87] wurde aus den herstellereigenen PEPs der Automobilindustrie ein allgemeingültiges branchenspezifisches Referenzmodell abgeleitet. Abbildung 13 zeigt die Produktentstehungsprozesse der einzelnen Hersteller und das daraus abgeleitete allgemeine Referenzmodell nach Göpfert.

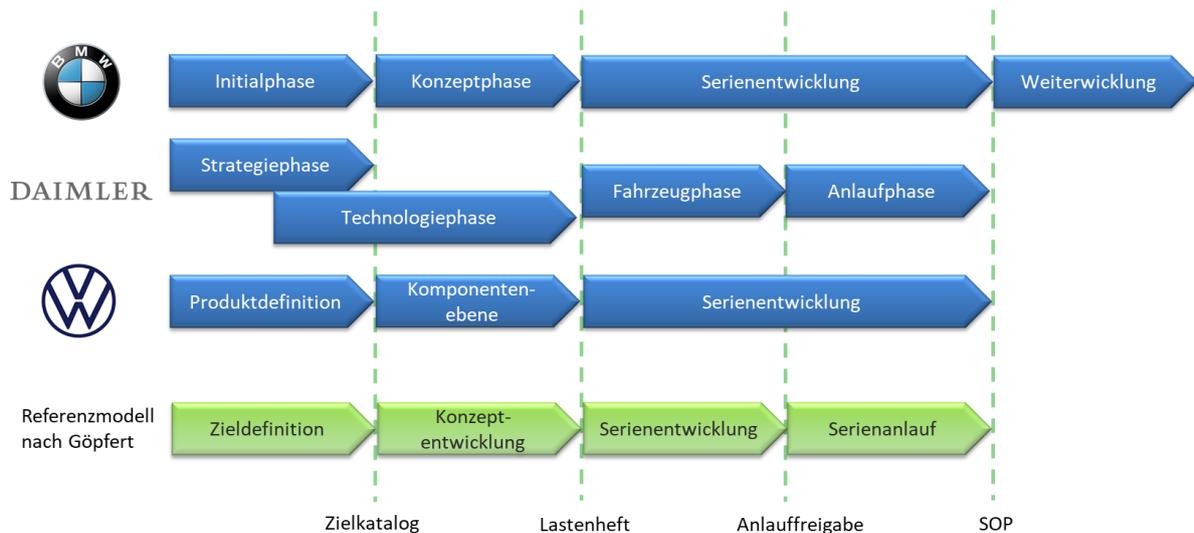


Abbildung 13 PEPs einzelner Hersteller und Referenzmodell nach Göpfert [87]

Vor dem eigentlichen fahrzeugspezifischen Produktentstehungsprozess erfolgt die Zieldefinition. Hierbei werden Fahrzeuganforderungen aus Kundensicht in mehreren Schritten konkretisiert und zum Abschluss der Phase als strategische Vorgaben im Zielkatalog bzw. Rahmenheft festgehalten [87]. Ausgehend vom Zielkatalog startet mit der Konzeptentwicklung die erste Phase des fahrzeugspezifischen Produktentstehungsprozesses. In dieser Phase erfolgt mit der Erstellung von Lösungsansätzen die operative Konkretisierung der strategischen Vorgaben des Zielkatalogs, welche im Lastenheft festgehalten werden [87]. In der zweiten Phase des fahrzeugspezifischen Produktentstehungsprozesses, der Serienentwicklung, werden die in der Konzeptentwicklung erarbeiteten Lösungsansätze zur Serienreife weiterentwickelt. Hierbei wird das Lösungskonzept in Teilschritten verfeinert, abgestimmt und schließlich „eingefroren“. So erfolgt zunächst bis zum Gateway Package-Freeze die Festlegung der Bauteile hinsichtlich ihrer Geometrie und Anordnung. Bis zum Gateway Design-Freeze erfolgt die vollständige Festlegung des Gesamtproduktes. Hiernach erfolgt eine Erprobung der entwickelten Funktionalität. Ist die Funktionalität erfolgreich getestet, startet die Beschaffung und/oder die Herstellung der Serienwerkzeuge. In der letzten Phase, dem Serienanlauf wird geprüft, ob alle Gewerke für die Massenfertigung vorbereitet sind. Diese Phase wird mit dem Gateway Start of Production, bei dem das erste Serienfahrzeug gefertigt wird, abgeschlossen. Abbildung 14 zeigt den fahrzeugspezifischen Produktentstehungsprozess mit den wesentlichsten Meilensteinen nach dem Referenzmodell von Göpfert.

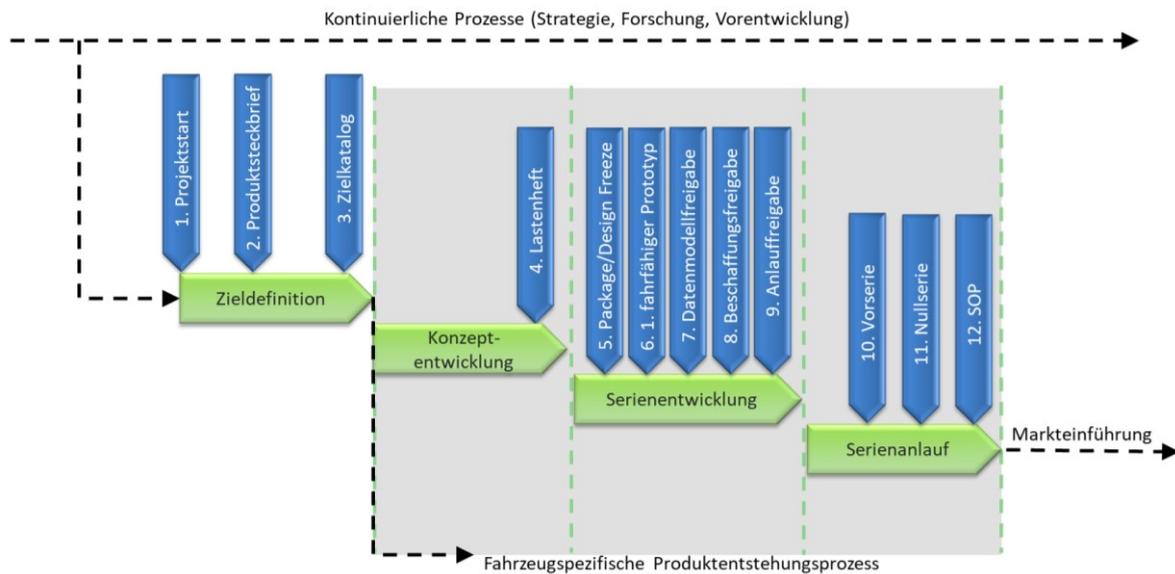


Abbildung 14 Fahrzeugspezifischer Produktentstehungsprozess nach Göpfert [87]

Die Entwicklung des Features Klimatisierung innerhalb des Produktentstehungsprozesses umfasst die Entwicklung von mechanischen, elektrischen und informationstechnischen Komponenten [39]. Hierfür hat sich ein Vorgehen in Anlehnung an die VDI-Richtlinie 2206 etabliert [93]. Die VDI-Richtlinie 2206 beschreibt im Kern ein Vorgehen auf Makroebene, ein Vorgehen auf Mikroebene und verschiedene Prozessbausteine für wiederkehrende Arbeitsschritte [39]. Auf der Makroebene wird ein aus der Softwaretechnik übernommenes und an die Anforderungen der Mechatronik angepasstes V-Modell als Problemlösungszyklus vorgeschlagen [92].

In jedem Zyklusdurchlauf werden, ausgehend von den jeweiligen Anforderungen, die Prozessbausteine Systementwurf, domänenspezifischer Entwurf, Modellbildung und -analyse, Systemintegration und Eigenschaftsabsicherung durchlaufen. Am Ende jedes durchlaufenen Zyklus entsteht ein Produkt, welches auch hier als Muster bezeichnet wird, und als solches im übergeordneten PEP eingeordnet werden kann. In jedem darauffolgenden durchlaufenen Zyklus wird dieses Produkt im Sinne der Produktreife weiter konkretisiert. So werden im Gesamtentwicklungsprozess eine Reihe von Mustern wie z.B. Labor-, Funktions-, Vorserien-, und Serienmuster etc. durchlaufen. Abbildung 15 zeigt das Durchlaufen der Problemlösungszyklen auf Makroebene. Eine herausgehobene Stellung wird innerhalb der VDI-Richtlinie 2206 dem Einsatz von Versuchsmodellen und Prototypen im Rahmen des Virtual Prototyping zugewiesen. Zum einen stehen in frühen Entwicklungsphasen in der Regel keine Fahrzeugprototypen für die Verifikation und Validierung zur Eigenschaftsabsicherung zur Verfügung [94]. Zum anderen herrscht das Bestreben aufgrund des hohen Zeit- und Kostenaufwands des Prototypenbaus, die Anzahl der physischen Prototypen niedrig zu halten [92]. Wie auch für andere Fahrzeugfunktionen hat sich für die Entwicklung von Klimasteuergeräten ein X-in-the Loop-Ansatz (XiL) etabliert, der auf einem modellbasierten Entwicklungsprozess basiert. Hierbei werden sowohl die Regel- und Steuerfunktionen als auch die betroffenen Regelstrecken mit modellbasierten Entwicklungswerkzeugen modelliert. Da in frühen Entwicklungsphasen die betroffenen Regelstrecken der realen physikalischen Komponenten nicht zur Verfügung stehen, werden diese durch mathematische Modelle abgebildet.

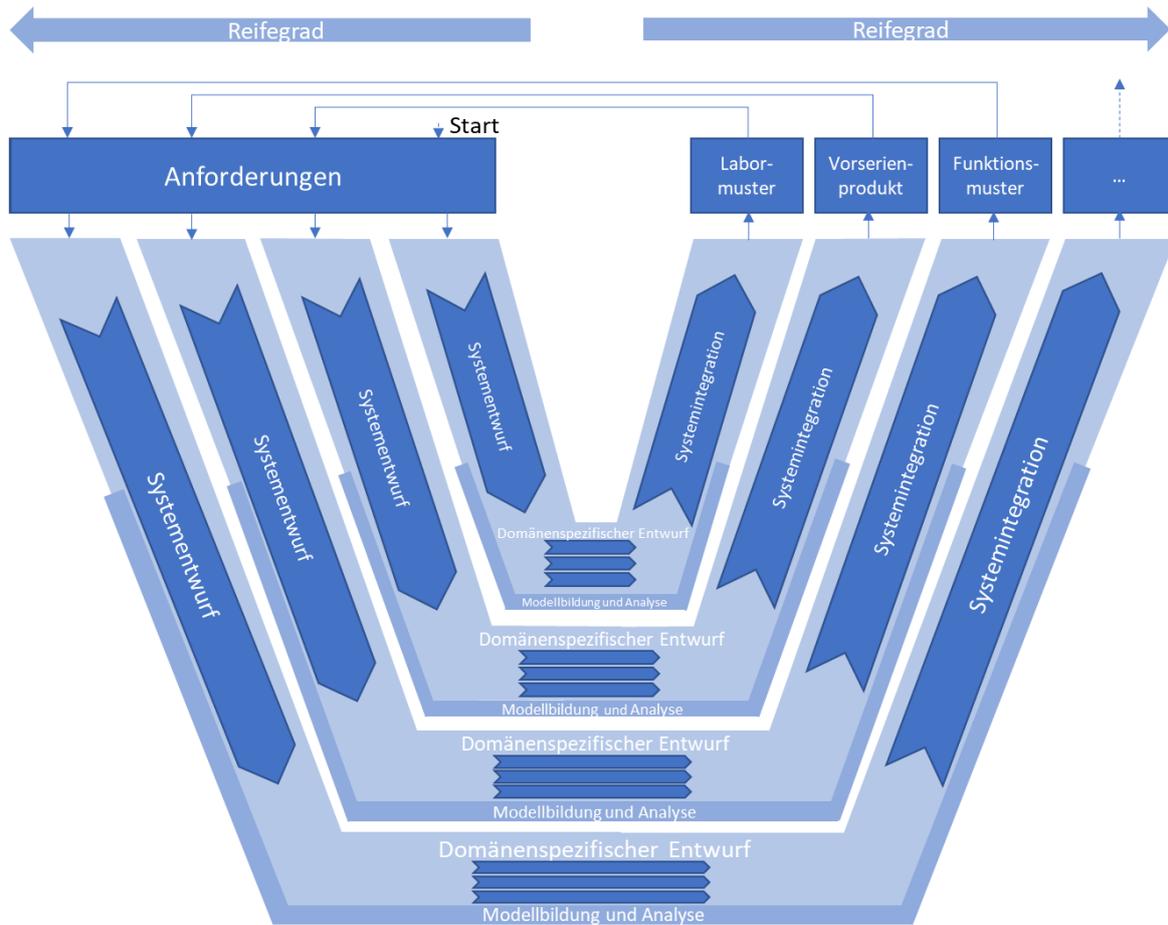


Abbildung 15 V-Modell als Problemlösungszyklus auf Makroebene gem. VDI Richtlinie 2206 [92]

Unter Verwendung dieser Modelle werden dann neue Softwaremodule für die Steuergeräte auf Entwicklungsrechnern entwickelt und mittels Model-in the-Loop-Simulation (MiL) verifiziert. Die MiL-Simulation dient damit der Evaluierung der entwickelten Regelungs- und Steuerungsalgorithmen in der Simulationsumgebung zu Beginn des Entwicklungszykluses. Die in der Regel durch grafische Beschreibungssprachen entwickelten blockschaltbildorientierten Modelle werden dann durch, in die Entwicklungsumgebung integrierte, automatische Codegeneratoren in Programmcode für die Zielhardware übersetzt. Hiernach erfolgt wiederum eine Eigenschaftsabsicherung in Form einer Software-in-the-Loop-Simulation (SiL). Wobei wiederum sowohl das Simulationsmodell der Regelstrecke als auch der Programmcode für die Zielhardware auf dem Entwicklungsrechner ausgeführt werden. Dabei wird das Verhalten des generierten Programmcodes, welcher in der Steuerung verwendet werden soll, verifiziert. In einer weiteren Entwicklungsstufe, der Prozessor-in-the-Loop-Simulation (PiL), wird der Programmcode auf einem dedizierten Microcontroller oder einem digitalen Signalprozessor getestet. Hierbei werden anstelle der später tatsächlich eingesetzten Zielhardware Evaluierungsboards verwendet, um z.B. den Ressourcenbedarf und die Laufzeit der Softwaremodule zu verifizieren. Nach der darauffolgenden Integration der Steuerungs- und Regelungssoftware auf die Zielhardware erfolgt die Hardware-in-the-Loop-Simulation (HiL). In dieser wird unter Verwendung eines Echtzeitsimulators das Zusammenspiel zwischen Hard- und Software des Steuergerätes in einer vernetzten Gesamtfahrzeugumgebung geprüft [95].

Um eine hohe Abbildungsgüte der verwendeten Simulatoren sicherzustellen und eine frühe Validierung auf Fahrzeugebene durchführen zu können, ist während des Entwicklungsprozesses von

Klimasteuergeräten ein Zusammenwirken von Simulation und Versuch erforderlich. Neben Einzelprüf- und Versuchsständen für einzelne Komponenten des Klimasystems wie dem Kühlkreislauf, verfügen die Hersteller z.T. über komplexe Klimawindkanäle. In diesen sind sehr genaue und reproduzierbare Versuche der gesamten Fahrzeugklimatisierungssysteme möglich. Mit den Klimawindkanälen können nahezu alle relevanten Umgebungsbedingungen wie Windgeschwindigkeit, Luftfeuchte, Lufttemperatur und Bestrahlung reproduziert werden [96]. In den Klimawindkanälen können zum einen relevante Koeffizienten wie z.B. die Wärmeleitfähigkeit von Kabinenelementen ermittelt, als auch im fortgeschrittenen Entwicklungsprozess die Klimasteuergeräte direkt im Prototypenfahrzeug geprüft werden [94]. Zum Ende des Entwicklungsprozesses erfolgen Tests der Fahrzeugprototypen im Rahmen von Straßenversuchen als auch im Rahmen von Erprobungsfahrten u. a. in speziellen klimatischen Regionen unter realen Klimabedingungen. Die aus den Tests gewonnenen Messdaten werden zur Kalibrierung und Verbesserung der Simulationsmodelle verwendet [96].

Der Einsatz des zur Eigenschaftsabsicherung eingesetzten Werkzeuges aus einer der drei beschriebenen Kategorien Simulationsmodelle, (Klima-)Gesamtfahrzeugprüfstand, Straßen- und Feldversuche (vgl. hierzu [39]) hängt demnach vom Fortschritt im Entwicklungsprozess als auch von der Produktreife der Teilsysteme und des Gesamtsystems ab.

Das Vorgehen nach dem angepassten V-Modell als Makrozyklus dient als „Richtschnur“ für die grundsätzliche Struktur des Vorgehens. Um die Flexibilität des Vorgehens zu erhöhen wird in der VDI 2206 ein aus dem System Engineering bekannter allgemeiner Problemlösungszyklus als Mikrozyklus vorgeschlagen. Dieser Mikrozyklus beginnt mit einer Situationsanalyse oder einer Zielübernahme. Entweder wird ein extern vorgegebenes Ziel übernommen und hierauf aufbauend eine Situationsanalyse durchgeführt, oder aus einer Situationsanalyse heraus selbstständig ein Ziel formuliert. Ausgehend von dem übernommenen oder abgeleiteten Zielen werden dann alternative Lösungsvarianten erarbeitet. Synthese- und Analyseschritte wechseln sich mehrfach ab. Hieran anschließend werden die konkretisierten Lösungsvarianten anhand der erstellten Anforderungen in der Regel durch Simulation oder Versuch analysiert. Kann durch eine oder mehrere Lösungsvarianten ein befriedigendes Ergebnis erzielt werden, wird der Mikrozyklus beendet. Hierbei wird entschieden, welche der gefundenen Lösungsvarianten die Grundlage der weiteren Planung im nächsten Schritt des Makrozykluses darstellen. Auf den Systementwurf folgt in jedem Makrozyklus der domänenspezifische Entwurf. Hierbei werden die im Systementwurf entwickelten Lösungskonzepte getrennt in den beteiligten Domänen weiter konkretisiert. Hierbei werden üblicherweise die Domänen Maschinenbau, Elektrotechnik und Informationstechnik unterschieden. Die Ergebnisse dieser Mikrozyklen werden wiederum in den folgenden Schritten des Makrozykluses zu einem Gesamtsystem integriert und deren Zusammenwirken untersucht.

Der Fokus dieser Arbeit liegt in der Entwicklung eines Lösungskonzepts zur Verbesserung der konventionellen Klimaregelungsfunktion eines Elektrofahrzeugs. Das weitere Vorgehen hierfür orientiert sich am Problemlösungszyklus der VDI-Richtlinie 2206 und kann daher als Mikrozyklus „modellbasierter Systementwurf“ des ersten Prozessschritts im ersten Makrozyklus der Richtlinie (vgl. Abbildung 15) interpretiert werden. Eine detaillierte Beschreibung des Vorgehens erfolgt im Kapitel 4. Der Mikrozyklus beginnt mit der Problemspezifikation. Hierbei stellen die Grundlagen der Fahrzeugklimatisierung eine zentrale Rolle dar. Daher erfolgt in den anschließenden Unterkapiteln eine detaillierte Beschreibung der Anwendungsdomäne der Fahrzeugklimatisierung.

3.2 Anforderungen an Kfz-Klimaanlagen

Die Anforderungen an die Klimatisierung von Elektrofahrzeugen ergeben sich zu einem großen Teil aus gesetzlichen Richtlinien und Normen. In [5] und [3] werden diese zusammenfassend dargestellt. Die zentralen Vorschriften, neben der allgemeinen Sicherheitsnorm für elektrische und elektronische Komponenten im Kraftfahrzeug ISO 26262, stellen die DIN 1946-3:2006-06 zur Klimatisierung von Personenkraftwagen und Lastkraftwagen, die US-amerikanischen FMVSS 103 (Federal Motor Vehicle Safety Standards) zur Scheibenenteisung, die DIN ISO 5128:1984-11 zur Akustik, EU-Verordnung 672/2010/EG für die Scheibenenteisung und -trocknung und die VDI-Richtlinie zu Hygiene-Anforderungen an die Lüftungstechnik in Fahrzeugen dar [97]. In der DIN 1946-3 werden die Mindestanforderungen an die Lüftung, Heizung und Klimatisierung von Fahrzeugkabinen spezifiziert. Durch richtig ausgelegte und abgestimmte Heizungs- und Klimaanlageensysteme soll bei allen Umgebungsbedingungen, wie Hitze mit Sonnenstrahlung und Feuchte, extremer Kälte, Regen und Schneefall, ein komfortables Klima im Fahrzeug erzeugt werden, um die Beibehaltung der Kondition und Konzentrationsfähigkeit von Fahrer und Fahrgästen zu unterstützen und eine mögliche Verkehrsgefährdung zu vermeiden [98]. Des Weiteren sollen Beschlagsfreiheit und schnelle Enteisung der Scheiben für eine freie und klare Sicht zur sicheren Fahrzeugführung gewährleistet sein. Zur Bewertung der Behaglichkeit im Fahrzeug sollen Innenraumlufttemperatur, Lufttemperaturschichtung, Kontakttemperatur, Luftgeschwindigkeit, direktes Anblasen des Körpers und Zugluft, Luftfeuchte, Strahlungsaustausch zwischen Menschen und umschließenden Bauteilen, Sonneneinstrahlung, Lufthygiene, Geräusche und Luftdruck im Fahrzeuginnenraum berücksichtigt werden. Um die Fahrzeuginnentemperatur behaglich zu gestalten, empfiehlt die Norm, wie in Abbildung 16 beispielhaft dargestellt, eine anzustrebende mittlere Lufttemperatur in Abhängigkeit der Außentemperatur.

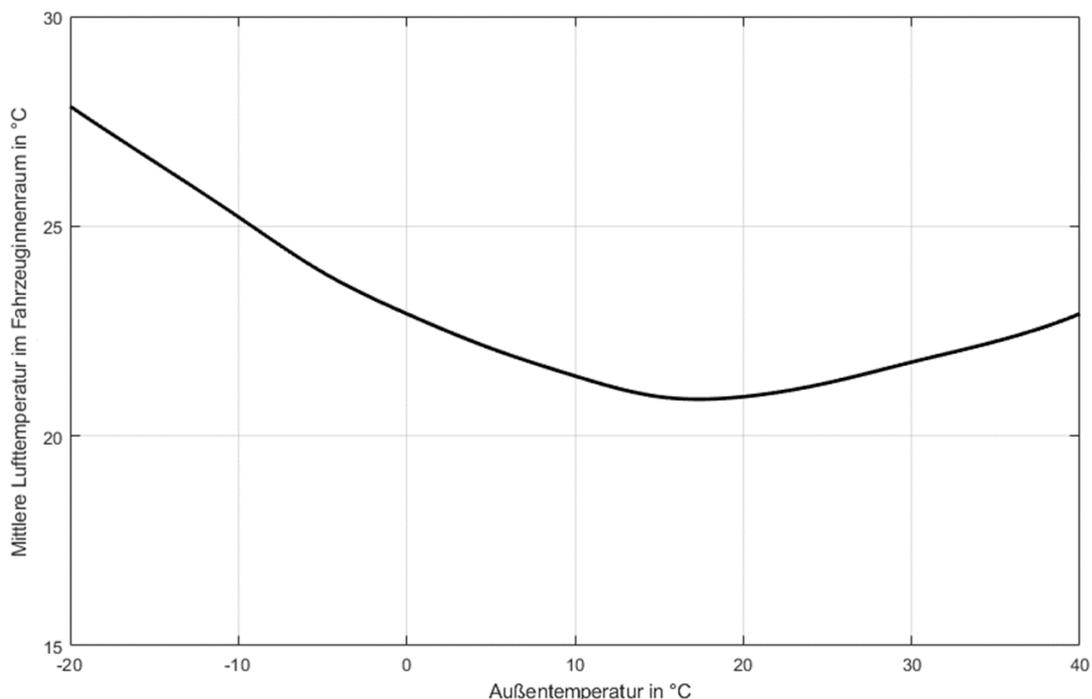


Abbildung 16 Anzustrebende mittlere Lufttemperatur gem. DIN 1946:3

Um den subjektiv empfundenen thermischen Komfort zu beurteilen, empfiehlt die Norm weiterhin einen mittleren Wärmebeurteilungsindex wie den Predicted Mean Vote (PMV) zu verwenden. Dieser Wärmebeurteilungsindex sagt anhand der durchschnittlichen Beurteilung einer großen Testgruppe

eine Klimabeurteilung auf einer 7-stufigen Beurteilungsskala voraus (siehe Tabelle 2). Der PMV wird in Abhängigkeit des Energieumsatzes, der wirksamen mechanischen Leistung, der Bekleidungsisolierung, des Bekleidungsflächenfaktors, der Lufttemperatur, der mittleren Strahlungstemperatur, der relativen Luftgeschwindigkeit, dem Wasserdampfpartialdruck, dem konvektiven Wärmeübergangskoeffizienten und der Oberflächentemperatur der Bekleidung ermittelt. Das Verfahren zur Ermittlung des PMV, basierend auf den Untersuchungen zur thermischen Behaglichkeit von P.O. Fanger [99], ist in der DIN EN ISO 7730 beschrieben [100].

PMV	Empfinden	Anzahl der Unzufriedenen in %
+3	heiß	100
+2	warm	78
1	etwas warm	26
0	neutral	5
-1	etwas kühl	26
-2	kühl	78
-3	kalt	100

Tabelle 2 Klimabeurteilungsskala des PMV gem. DIN EN ISO 7730

Die DIN 1946-3 empfiehlt zur Bestimmung des PMV eine Versuchsdurchführung im Fahrzeug durch Bewertung von Versuchspersonen im realen Betrieb. Hierbei ist ein Wärmebeurteilungsindex von $PMV=0$ anzustreben. Des Weiteren werden in der Norm Richtwerte für Klimaanlagen gegeben. Die relative Luftfeuchte im Komfortbereich sollte gem. der DIN im Bereich zwischen 30 % und 60 % liegen. Da die Beschlagsfreiheit ebenfalls sicherzustellen ist, sollte die Taupunkttemperatur der Luft im Innenraum des Fahrzeugs im Frontbereich unterhalb der Scheibeninnenseitentemperatur sein. Hierbei kann die Luftfeuchte den Komfortbereich unterschreiten. So sollten bei der Auslegung von Fahrzeugklimaanlagen für Mitteleuropa Außentemperaturen von -20 °C bis 40 °C , die dabei auftretenden Luftfeuchten und eine Sonneneinstrahlung bis zu $1\,000\text{ W/m}^2$ berücksichtigt werden. Im Heizfall sollte eine Klimaanlage bei verbrauchsarmen Fahrzeugen, hierzu zählen in der Regel batterieelektrische Fahrzeuge, bei einer Außentemperatur von -20 °C nach 30 min Außenluftbetrieb mindestens 15 °C erreichen. Im Kühlfall sollte bei einer Außen- und Innentemperatur von ca. 40 °C bei einer relativen Luftfeuchte von ca. 40 % und einer Sonneneinstrahlung von ca. 1000 W/m^2 die mittlere Lufttemperatur in Kopfhöhe nach spätestens 30 Minuten kleiner als 30 °C sein.

Die amerikanische FMVSS 103 und die EU-Verordnung 672/2010/EG beschreiben ebenfalls Mindestanforderungen an die Klimatisierung und definieren Testverfahren und Richtwerte zur Sicherstellung der Beschlagsfreiheit und Enteisung.

Die VDI-Richtlinie 6032 definiert Hygiene-Anforderungen an die Lüftungstechnik in Fahrzeugen. Hierbei wird eine Partikelfilterung für die Zuluft und Umluft zur Fernhaltung von partikelförmigen Stoffen, Mikroorganismen und deren Stoffwechselprodukten sowie Wartungszyklen empfohlen. Da der Mensch mit seiner Atmung und seinen Ausdünstungen eine wesentliche Quelle von Verunreinigungen der Innenraumluft darstellt, muss durch die Fahrzeugklimatisierung eine geeignete Zufuhr von Frischluft gewährleistet werden [101].

Kategorie	Beschreibung der Raumluftqualität	CO ₂ -Konzentration über der Außenluftkonzentration in ppm
IDA 1	Hohe Raumluftqualität	< 400
IDA 2	Mittlere Raumluftqualität	400-600
IDA 3	Mäßige Raumluftqualität	600-1000
IDA 4	Niedrige Raumluftqualität	> 1000

Tabelle 3 Bewertung der Luftqualität nach CO₂-Konzentration gem. DIN EN 13779

Unter dem Aspekt der Luftqualität sind des Weiteren die Normen DIN EN 16798 bzw. die DIN EN 13779 zu berücksichtigen. Hierin werden unter anderem IDA-Indizes (Indoor Air) zur Bewertung der Raumluftqualität definiert. Tabelle 3 zeigt die Klassifizierung der Luftqualität in IDA-Kategorien nach CO₂-Konzentration über der Außenluftkonzentration. Hierbei ist zu beachten, dass CO₂-Messwerte der Außenluft bis zu 620 ppm noch als ausreichende Luftqualität zu bewerten sind. Bis zu dem als Pettenkoffer-Wert bezeichneten absoluten CO₂-Konzentrationswert von 1000 ppm gilt die Raumluft als unbedenklich [101].

Weitere funktionale und nichtfunktionale Anforderungen werden durch die OEMs und Zulieferer festgelegt und unterscheiden sich je nach Modell, Leistung, Fahrzeug, möglichen Einsatzorten des Fahrzeugs und deren klimatischen Bedingungen. Beispiele für weitere funktionale Anforderungen sind z.B. eine getrennte Einstellbarkeit für Temperaturen von Fahrer und Beifahrer oder ein Heiz- und Lüftungsbetrieb bei einem Ausfall des Klimakompressors. Ein Beispiel für eine nichtfunktionale Anforderung ist der Ausschluss von Rückwirkungen auf das Bordnetz im Fehlerfall der Klimasteuerung (vgl. [102]).

3.3 Aufbau und Funktionsweise von Fahrzeugklimaanlagen

Heutige Fahrzeugklimatisierungssysteme unterscheiden sich im Wesentlichen nach Funktionen und Automatisierungsgrad. Eine detailliertere Beschreibung der verschiedenen Ausführungen aktueller Fahrzeugklimatisierungssysteme von Fahrzeugen mit alternativen Antrieben findet sich in [40]. Die einfachste marktübliche Ausführung als Heizungs- und Lüftungsanlage stellt im eigentlichen Sinne kein Klimatisierungssystem dar, da nur Funktionen des Heizens sowie der Frischluftzufuhr und der Luftreinigung erfüllt werden. Im Gegensatz hierzu erfüllen Systeme, die herstellereitig oft als Kfz-Klimaanlage bezeichnet werden, zusätzlich die Funktionen des Kühlens und Entfeuchtens. Diese Systeme werden nach ihren Funktionen auch oft allgemein als HVAC-Systeme (Heating, Ventilation and Air-Conditioning) bzw. in der deutschsprachigen Literatur als HLK-Systeme (Heizungs-, Lüftungs- und Klimaanlage) bezeichnet. Hierbei unterscheidet man in der Regel nach dem Grad der Automatisierung zwischen manuell regelbaren, teilautomatisierten und vollständig selbstregelnden Systemen. Vollautomatisierte Klimatisierungssysteme, herstellereitig oft als Klimaautomatik oder Climatronic bezeichnet, unterscheiden sich weiterhin nach Anzahl der einstellbaren Klimatisierungszonen (1C-/2C-/ 4C-Climatronic). Der prinzipielle Aufbau und die Funktionsweise heutiger Kfz-Klimaanlagen gestalten sich sehr ähnlich. So bestehen sie in der Regel aus den Hauptkomponenten des Klimasteuergerätes, des Luftverteilungssystems, des Klima- bzw. Kältekreislaufs, des Pollenfilters und eines Wärmetauschers.

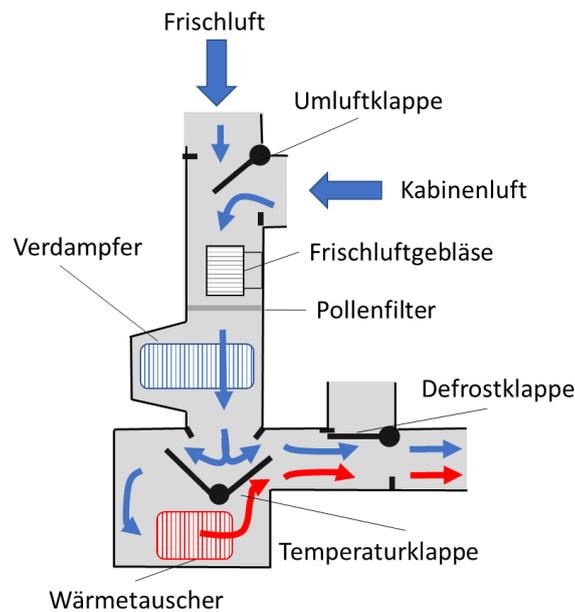


Abbildung 17 Prinzipdarstellung der Luftführung im Klimagerät

Je nach Hersteller, Fahrzeugsegment und Ausstattung können die HVAC-Systeme mit weiteren Komponenten wie Sitz- und Lenkradbeheizung, Wärmepumpen, Sitzbelüftungen und -kühlungen, Nackenheizungen, beheizbaren Front- und Rückscheiben und Beduftungsanlagen etc. ausgestattet sein. Die Luftführung im Klimagerät, in welchem meist die Hauptkomponenten zusammengefasst sind, gestaltet sich ebenfalls meistens nach einem ähnlichen Prinzip. Dieses grundlegende Prinzip ist in Abbildung 17 in Anlehnung an [103] dargestellt.

Durch entsprechende Lufteinlassöffnungen tritt Frischluft von außen und Kabinenluft in das Klimagerät ein. Der jeweilige Anteil von zugeführter Frisch- bzw. Kabinenluft wird durch die Stellung der Umluftklappe bestimmt. Die Stellung der Umluftklappe wird über elektrisch angesteuerte Stellmotoren gesteuert. Ein im Klimagerät verbautes elektrisch angetriebenes Frischluftgebläse erzeugt den für den

Lufttransport notwendigen Massenstrom. Im weiteren Verlauf durchströmt die Luft den Pollenfilter und den Verdampfer. Dieser ist Teil des Kältemittelkreislaufes. Bei eingeschalteter Klimaanlage wird die vorbeiströmende Luft gekühlt und entfeuchtet. Im weiteren Luftpfad folgt die Temperaturklappe. Über sie wird das Massenverhältnis zwischen gekühlter und erwärmter Luft und damit die Ausströmtemperatur der Luft geregelt. Der Anteil der Luft, der dabei den Wärmetauscher durchströmt, wird erwartungsgemäß erwärmt. Im Falle einer Mehrzonenklimatisierung werden mehrere Temperaturklappen in einem geteiltem Luftpfad verbaut, so dass sich durch unterschiedliche Stellung der verschiedenen Temperaturklappen unterschiedliche Ausströmtemperaturen in den einzelnen Zonen realisieren lassen. Im weiteren Verlauf teilt sich der Luftpfad auf die unterschiedlichen Ausströmer für Defrostaströmer sowie Fußraum- und Schalttafelauströmer auf. Der jeweilige Anteil wird dabei wiederum durch verschiedene Luftklappen geregelt, welche wiederum durch einzelne elektrische Stellmotoren angesteuert werden.

Im Gegensatz zu verbrennungsmotorisch betriebenen Fahrzeugen wird bei batterieelektrisch betriebenen Fahrzeugen im Kühlkreislauf ein elektrischer Klimakompressor und im Heizkreislauf eine elektrische Hochvoltheizung verwendet. Die grundlegende Funktionsweise des geschlossenen Kühlkreislaufes unterscheidet sich nur unwesentlich von der Funktionsweise bei verbrennungsmotorisch angetriebenen Fahrzeugen und ist in Abbildung 18 in Anlehnung an [103] schematisch dargestellt.

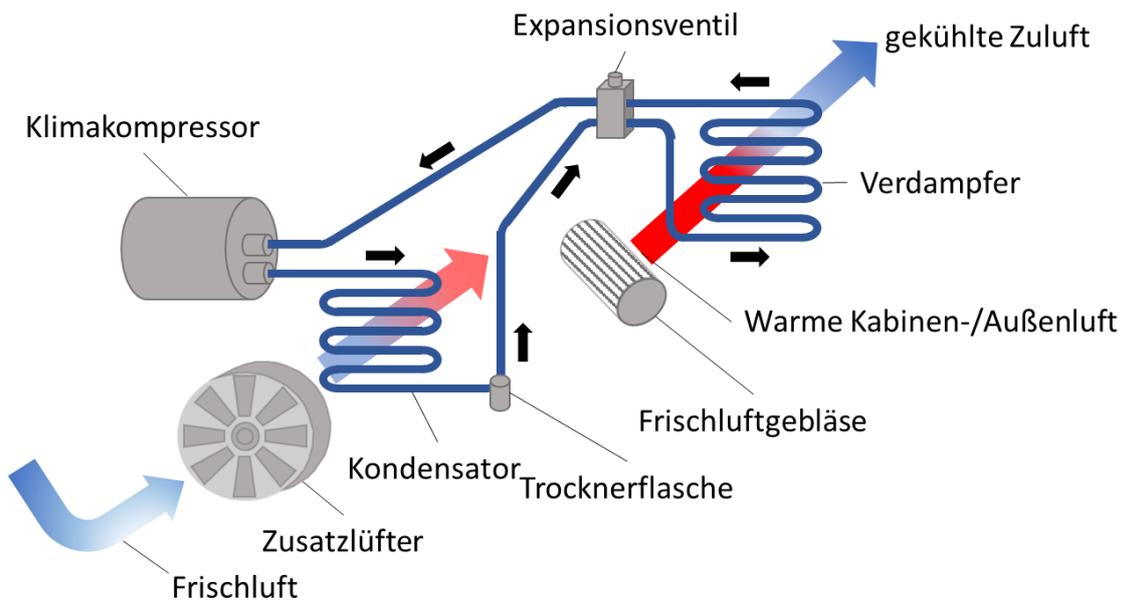


Abbildung 18 Funktionsweise des Kühlkreislaufs

Ein Klimakompressor verdichtet das Kältemittel. Durch den Verdichtungsprozess wird das Volumen des gasförmigen Kältemittels verringert. Durch den erhöhten Druck steigt die Temperatur des Kältemittels. Hiernach wird das gasförmige Kältemittel mit einer Temperatur von ca. 50 °C bis 70 °C in die Hochdruckleitung in Richtung des Kondensators gepresst. Das Kältemittel durchströmt anschließend den Kondensator, welcher an der Fahrzeugfront verbaut ist. Der Kondensator wird unter Zuhilfenahme von Zusatzlüftern von Frischluft umströmt und dadurch gekühlt. Beim Durchströmen des Kondensators wird das Kältemittel abgekühlt und wechselt hierdurch seinen Zustand in den flüssigen Aggregatzustand. Hinter dem Kondensator wird dem Kältemittel in der Trocknerflasche Feuchtigkeit entzogen. Im weiteren Verlauf passiert das Kältemittel das Expansionsventil, wodurch es entspannt und im Verdampfer wiederum in den gasförmigen Aggregatzustand wechselt. Die hierzu notwendige Verdampfungsenthalpie wird über Wärmeübertragung und Konvektion der vorbeiströmenden Luft entzogen.

Die den Verdampfer umströmende Luft wird dadurch abgekühlt und entfeuchtet. Der notwendige Luftmassenstrom wird über das Frischluftgebläse erzeugt. Nach dem Verdampfer wird das Kühlmittel wieder vom Kompressor angesaugt und erneut verdichtet.

Die grundlegende Funktionsweise des Heizkreislaufs unterscheidet sich in der Regel ebenfalls nur unwesentlich von der Funktionsweise bei verbrennungsmotorisch angetriebenen Fahrzeugen und ist in Abbildung 19 in Anlehnung an [104] schematisch dargestellt.

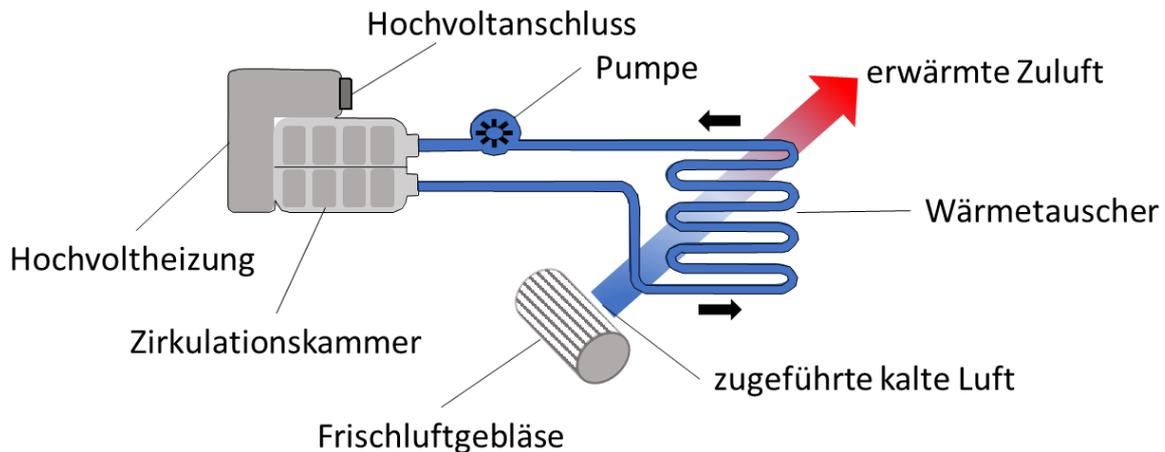


Abbildung 19 Funktionsweise des Heizkreislaufs

Da hier keine Abwärme eines Verbrennungsmotors zum Erwärmen des Kühlmittels verwendet werden kann, wird das Kühlmittel über eine elektrische Hochvoltheizung erhitzt. In der Hochvoltheizung sind mehrere Heizkreise integriert, die über pulsweitenmodulierte Signale (PWM) angesteuert werden und so die erforderliche Wärmeleistung bereitstellen [104]. Im Luftführungskanal wird Wärme des erhitzten Kühlmittels an die Umgebungsluft über den Wärmetauscher abgegeben. Der notwendige Luftmassenstrom wird auch hierbei über das Frischluftgebläse erzeugt. Der Wirkungsgrad des Heizkreislaufs liegt bei rund 90 % und ist im Wesentlichen von der Menge der im Kreislauf befindlichen Flüssigkeit abhängig [105].

Eine alternative Variante des Heizkreislaufs ist die Verwendung eines direkten elektrischen Zuheizers ohne Wärmetauscher. Hierbei werden PTC-Heizelemente direkt im Luftführungskanal kurz vor den Ausströmern integriert, welche die Luft dann direkt erwärmen.

3.4 Regelung von Kfz-Klimaanlagen

Eine Vielzahl unterschiedlicher Betriebsverfahren zur Einstellung von Luftfeuchtigkeit, Luftverteilung und Lufttemperatur durch Fahrzeugklimaanlagen sind in der Patentliteratur, wie z.B. in [106], [107], [108] und [109] beschrieben. Die Verfahren unterscheiden sich zum Teil erheblich je nach Ausführung der Heiz- und Klimageräte sowie der eingesetzten Sensorik und Aktorik. Allen Verfahren gemein ist jedoch eine gekoppelte Mehrgrößenregelung mit mehrfacher Kaskadierung durch eingesetzte Teilregelungen. Im Folgenden wird beispielhaft eine mögliche Regelung einer Fahrzeugklimaanlage, die sich an den eingesetzten Versuchsträger anlehnt und durch diesen plausibilisiert worden ist, beschrieben. Dieses Regelungsverfahren wurde in dieser Arbeit in der Simulationsumgebung implementiert. Durch das vorgestellte Verfahren wird die Innenraumtemperatur im Fahrzeug unter Sicherstellung der Beschlagfreiheit geregelt. Die Vorgabe der Solltemperatur erfolgt entweder direkt durch manuelle Eingabe des Bedieners am Klimabediengerät oder durch eine Berechnung der Komforttemperatur durch die Innenraumtemperatursteuerung bei ausgewähltem Automatikmodus. Die Regelung der Luftmenge durch die Frischluftgebläsesteuerung und der Raumluftqualität durch die Umluftklappensteuerung erfolgen hierbei extern. Abbildung 20 zeigt vereinfacht das Prinzip der Gesamtregelung. Die Hauptregelung des Systems erfolgt innenraumtemperaturgeführt. Hierbei wird in Abhängigkeit der aktuellen IST- und SOLL-Temperaturen im Fahrzeuginnenraum durch den Temperaturregler die Stellung der Temperaturklappe geregelt, um so die erforderliche Ausblastemperatur zur Realisierung der SOLL-Innenraumtemperatur zu erreichen.

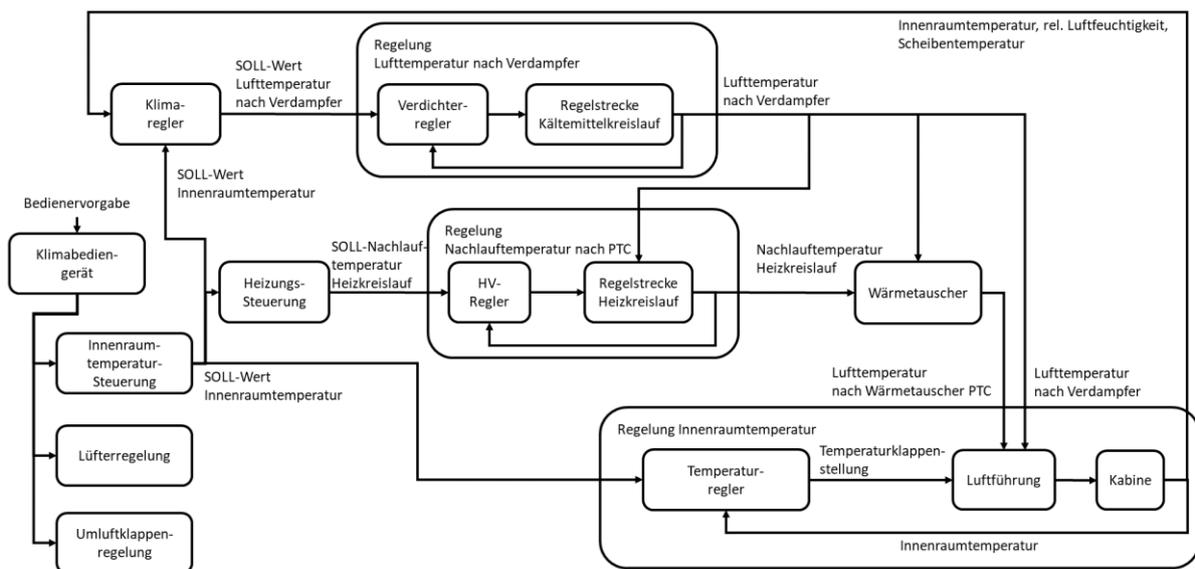


Abbildung 20 Prinzip der innenraumtemperaturgeführten Regelung einer Klimaanlage

Die SOLL-Temperatur des Fahrzeuginnenraums dient des Weiteren zur Berechnung der Führungsgrößen weiterer nachgelagerter Teilregelungen des Systems. So wird zum einen durch den Klimaregler in Abhängigkeit der Solltemperatur des Innenraumes, des Taupunktabstandes der Frontscheibe und der relativen Luftfeuchtigkeit in der Kabine ein SOLL-Temperaturwert der Luft nach dem Verdampfer berechnet. Dieser dient wiederum als Führungsgröße der Verdichterregelung im nachgeordneten Kältemittelkreislauf. Hierdurch wird einem Überschreiten der übergeordneten Solltemperatur des Innenraums (Funktion Kühlen), einem Überschreiten der Komfortfeuchtigkeit als auch der Scheibenbeschlaggefahr (Funktion Entfeuchten) entgegengewirkt.

In einem weiteren Zweig der untergeordneten Regelung wird durch die Heizungssteuerung einem Unterschreiten der übergeordneten Solltemperatur des Innenraums (Funktion Heizen) entgegengewirkt. Durch die Heizungssteuerung wird in Abhängigkeit der Außentemperatur und der Solltemperatur des Innenraums die Führungsgröße des Heizkreislaufs berechnet. Hierbei handelt es sich um einen SOLL-Wert der Nachlauftemperatur des Kältemittels im Heizkreislauf. Im Folgenden erfolgt eine detailliertere Beschreibung der einzelnen Teilregelungen.

3.4.1 Regelung des Kältemittelkreislaufs

Bei verbrennungsmotorisch angetriebenen Fahrzeugen ist der Kompressor in der Regel über einen Riemtrieb mit dem Verbrennungsmotor mechanisch gekoppelt. Im Gegensatz hierzu wird bei BEVs ein elektrischer Klimakompressor verwendet, der eine externe Regelung erfordert. Eine Möglichkeit einer externen Regelung der Lufttemperatur hinter dem Verdampfer über die Kompressordrehzahl wird in [95] beschrieben. Die Kälteleistung am Verdampfer ist abhängig von den Umgebungsbedingungen und dem Volumenstrom des Kältemittels. Letzterer ist abhängig von der Stellung des Expansionsventils und des Drucks des Kältemittels. Der Druck des Kältemittels wird wiederum über die Drehzahl des Kompressors bestimmt. Abbildung 21 zeigt vereinfacht den Wirkungsablauf der Verdichterregelung. Zur Regelung wird ein Temperatursensor zur Messung der Lufttemperatur verwendet. Dieser ist in der Luftführung hinter dem Verdampfer angeordnet. Durch einen übergeordneten Klimaregler wird als Führungsgröße eine Solltemperatur der Luft nach dem Verdampfer vorgegeben. Der Verdampferregler berechnet aus der Regelabweichung zwischen IST- und SOLL-Temperatur die Kompressordrehzahl als Stellgröße. Über die Kompressordrehzahl wird über die Regelstrecke des Kältekreislaufs die Lufttemperatur hinter dem Verdampfer beeinflusst. Diese stellt die Regelgröße des Regelkreises dar, welche über den Temperatursensor zurückgeführt wird.

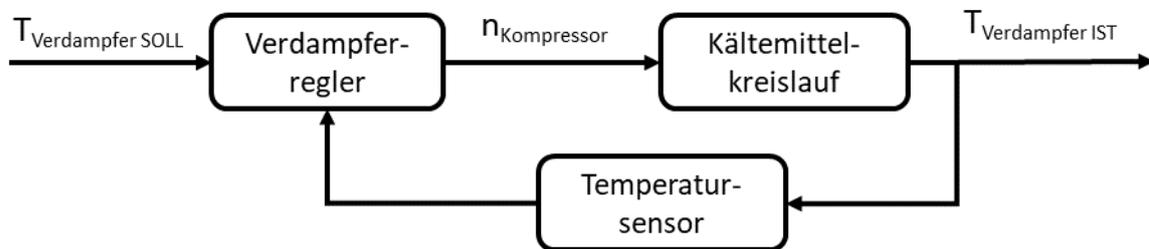


Abbildung 21 Wirkungsablauf Verdampferregelung

Neben diesen Elementen werden im Kältemittelkreislauf weitere Aktoren und Sensoren wie z.B. Ventile, Zusatzlüfter, Drucksensoren und Sicherheitsschalter verwendet. Da die Leistungsaufnahme des Kältemittelkreislaufs aber im Wesentlichen durch den Kompressor bestimmt wird, wird diese im weiteren Verlauf der Arbeit vernachlässigt.

3.4.2 Regelung des Heizkreislaufs

Die Erwärmung der Luft innerhalb des Klimagerätes erfolgt, wie in 3.3 beschrieben, über einen integrierten Wärmetauscher. Hierbei erfolgt die Wärmeübertragung von dem den Wärmetauscher durchströmenden Kühlmittel auf die ebenfalls den Wärmetauscher durchströmende Luft. Das Kühlmittel wiederum wird über eine elektrische Hochvoltheizung (PTC) erwärmt. Diese wird über den HV-Heizungsregler über pulsweitenmodulierte Signale so angesteuert, dass sich die Nachlauftemperatur im Heizkreislauf auf eine durch das Heizungssteuergerät vorgegebene SOLL-Nachlauftemperatur einregelt. Die SOLL-Nachlauftemperatur des Heizkreislaufs wird über die übergeordnete Heizungs-

steuerung anhand des SOLL-Wertes der Innenraumtemperatur und der Außentemperatur berechnet. Abbildung 22 veranschaulicht den Wirkungsablauf der Heizungsregelung.

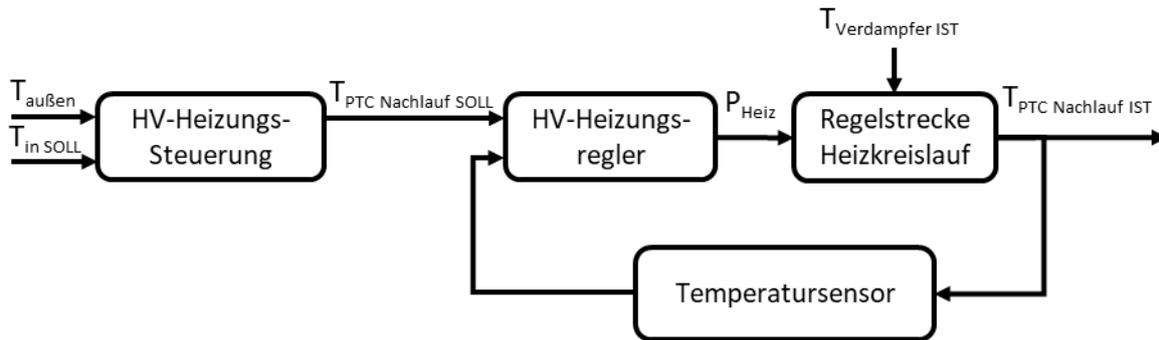


Abbildung 22 Wirkungsablauf Heizkreisregelung

3.4.3 Innenraumtemperaturregelung

Die Regelung der Temperatur in der Fahrzeugkabine erfolgt innerhalb des Temperaturregelkreises. Hierbei wird im Hauptregelkreis aus der vorgegebenen Innenraumsolltemperatur und der gemessenen Innenraumtemperatur eine Regelabweichung berechnet. Die Messung der Innentemperatur erfolgt mittels eines am Klimabediengerät verbauten Temperatursensors. Die Regelung der Innenraumtemperatur erfolgt über die Ansteuerung der Stellmotoren der im Luftkanal verbauten Temperaturklappen. Dadurch wird das Mischungsverhältnis der am Verdampfer gekühlten Luft und der am Wärmetauscher des Heizkreislaufs erwärmten Luft eingestellt. Die Lufttemperaturen der gekühlten Luft $T_{Verdampfer IST}$ und $T_{Heiz IST}$ werden durch die Klimaregelung und die Heizkreislaufregelung eingestellt und stellen im Temperaturregelkreis nicht beeinflussbare Störgrößen dar. Abbildung 23 zeigt den Wirkungsablauf der Innenraumtemperaturregelung.

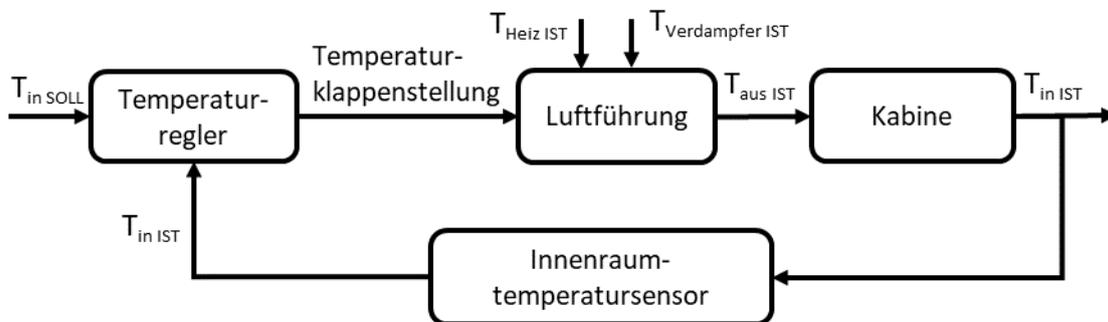


Abbildung 23 Wirkungsablauf Innenraumtemperaturregelung

3.4.4 Regelung des Kühlkreislaufs

Über die Regelung des Kühlkreislaufs werden die Innentemperatur und der Wassergehalt der Innenluft beeinflusst. Die Regelstrecke des Kühlkreislaufs umfasst neben dem kaskadierten Kältemittelkreislauf die gesamte Luftführung und die Fahrzeugkabine. Der Regler des Kühlkreislaufs, im Folgenden als Klimaregler bezeichnet, wirkt einem Überschreiten der relativen Luftfeuchtigkeit über die Komfortfeuchte und die Beschlagsfeuchte, sowie negativen Temperaturdifferenzen zwischen SOLL- und IST-Innenraumtemperatur entgegen. Die Regelung des Kühlkreislaufs hat damit 3 Führungsgrößen. Dies sind die SOLL-Innenraumtemperatur des Klimageräts, der SOLL-Taupunktastand und die Grenzfeuchte. Die SOLL-Innenraumtemperatur wird durch die übergeordnete Innenraumtemperatursteuerung vorgegeben. Der SOLL-Taupunktastand ist ein Sicherheitsabstand zum aktuellen Taupunktastand, welcher aus der Differenz der aktuellen Scheibentemperatur und der gemäß (28) ermittelten

Taupunkttemperatur der Scheibe gebildet wird. Die Grenzfeuchte φ_{Grenz} ist die Obergrenze des Komfortbereichs der relativen Luftfeuchtigkeit. Durch Testfahrten mit einem Referenzfahrzeugs wurde eine Obergrenze von 80 % relativer Luftfeuchtigkeit bestimmt. Der Klimaregler verändert die Stellgröße $T_{Verdampfer\ SOLL}$ so, dass den drei Regelabweichungen entgegengewirkt wird. Hierbei kann eine starke positive Regelabweichung der IST-Innenraumtemperatur verursacht werden. Dabei wird die Lufttemperatur oft so stark gekühlt, dass ein anschließendes Aufheizen in der nachgeschalteten Heizungsregelung erforderlich wird. Um ein Entgegenwirken von Heiz- und Kühlleistung zu minimieren, kann das Zusammenspiel der Heiz- und Kühlfunktionen über eine Hysterese realisiert werden. Neben den genannten Regelabweichungen werden zum Teil weitere Eingänge zur Kompensation von Störgrößen der Regelstrecke eingesetzt (vgl. [110]). Diese werden in dieser Arbeit nicht berücksichtigt.

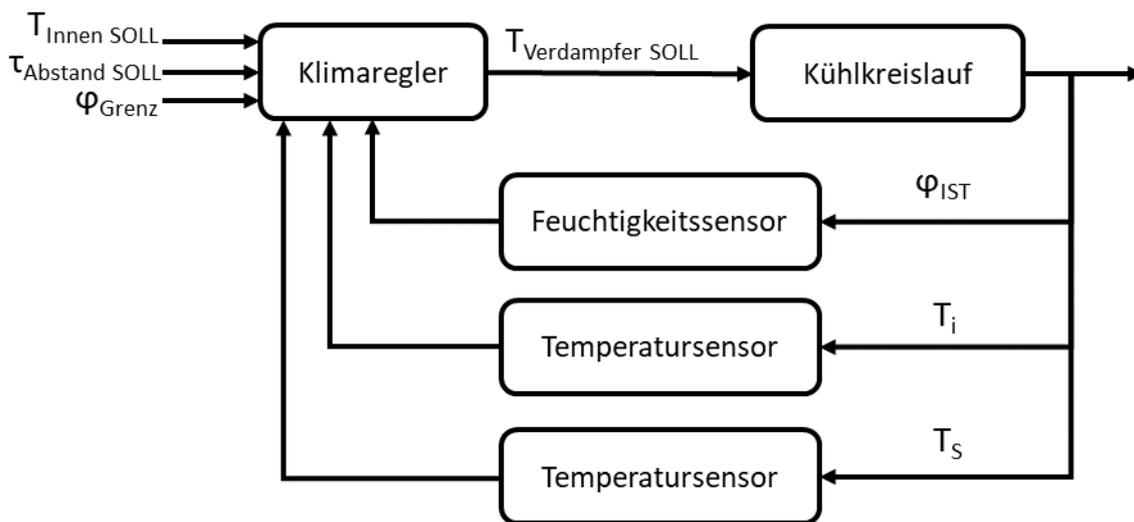


Abbildung 24 Wirkungsablauf Kühlkreisregelung

Zur Regelung werden mindestens ein Innen- und Außentemperatursensor sowie ein Luftfeuchtigkeitssensor im Fahrzeuginnenraum eingesetzt. Werden keine weiteren Sensoren zur Messung der Scheibentemperatur und der Außenluftfeuchte verwendet, müssen diese Werte durch den Regler anhand der vorhandenen Sensorik geschätzt werden. Die Umsetzung der Klimaregelung erfolgt in der Regel über mehrdimensionale Kennfelder. Hierbei werden diskret definierten mehrdimensionalen Punkten der Eingangsgrößen, welche als Stützstellen bezeichnet werden, definierte Stützwerte als Ausgangsgrößen tabellarisch zugeordnet. Durch geeignete Interpolationsverfahren werden dann daraus die Stellgrößen ermittelt. Der Wertebereich der SOLL-Verdampfer Temperatur als Stellgröße bei aktiver Klimatisierung am Referenzfahrzeug liegt hierbei zwischen 2 °C - 14 °C. Zur Vereinfachung der Regelung in der Simulation wird eine Mehrpunktregelung implementiert, die im Kühl- oder Entfeuchtungsfall auf eine SOLL-Verdampfer Temperatur von 2 °C einstellt. Wird kein Kühl- oder Entfeuchtungsfall erkannt, so werden hierbei Klimaregler und Kühlkreisregelung deaktiviert.

3.4.5 Regelung von Umluftklappe und Frischluftgebläse

Die Regelung der Umluftklappenstellung erfolgt i.d.R. außentemperatur-, taupunkt- und/oder luftgütegeführt. Hierfür ist am Frischluftkanal der Luftführung ein zusätzlicher Luftgütesensor verbaut. Dieser Sensor misst die in der zugeführten Frischluft enthaltenen Anteile von oxidierbaren und reduzierbaren Gasen wie Stickoxiden und Kohlenmonoxid. Liegt keine Grenzwertüberschreitung der Luftgüte und des Taupunktabstandes vor, so wird die Umluftklappe kennfeldgesteuert über die Außentemperatur geregelt. Bei einer Grenzwertüberschreitung der Luftgüte wird die Umluftklappe geschlossen. Bei

einer Grenzwertüberschreitung des Taupunktabstandes wird die Umluftklappe in Abhängigkeit des Verhältnisses von Innen-/Außentemperatur und des Verhältnisses von Innen-/Außenluftfeuchtigkeit ebenfalls kennfeldgesteuert geregelt. Der zur Klimatisierung notwendige Luftvolumenstrom wird durch ein Frischluftgebläse erzeugt. Hierbei wird der Gebläsemotor des Frischluftgebläses über ein PWM-Signal angesteuert. Die Ansteuerung erfolgt zeitgesteuert in Abhängigkeit der Regelabweichung der Temperatur- und Klimaregelung. Im Rahmen dieser Arbeit werden die Regelungen von Umluftklappe und Frischluftgebläse als externe Regler angenommen, deren Stellverhalten der modellprädiktiven Regelung bekannt ist.

4 Situationsanalyse und Zielformulierung

Ziel der Arbeit ist die Entwicklung eines Lösungskonzeptes für eine verbesserte temperaturgeführte Regelung einer Einzonen-Klimaanlage in der in den Kapiteln 3.3 und 3.4 beschriebenen Ausführung. Der Fokus liegt hierbei auf einer Reduzierung des Energiebedarfs bei gleichzeitiger Erfüllung der übernommenen Anforderungen der konventionellen Regelung. Das Vorgehen in dieser Arbeit basiert auf dem Ist-Zustand-orientierten Vorgehen im Mikrozyklus gemäß VDI-Richtlinie 2206. Ausgehend vom Entwicklungsziel wird zunächst eine Situationsanalyse des bestehenden Systems durchgeführt. Hierbei wird - ausgehend von den übernommenen Anforderungen an die konventionelle Regelung - eine Untersuchung der Regelgüte und des Energiebedarfs eines Referenzsystems durchgeführt. Als Referenzsystem dient ein von der TLK-Thermo GmbH erstelltes thermisches Gesamtfahrzeugmodell eines BEV. Zur Modellvalidierung wurden reale Straßenversuche mit einem mit Messtechnik ausgestatteten E-Elektrofahrzeug vom Typ VW-e-Golf durchgeführt. Zur Bewertung der Energieeffizienz werden basierend auf [111] aus klimatischen Daten und Pkw-Nutzungsverhalten in Deutschland Versuchsszenarien abgeleitet und hierfür Simulationen am thermischen Gesamtfahrzeugmodell durchgeführt. Aus den Ergebnissen dieser Untersuchung erfolgt die Zielformulierung. Hierbei werden, basierend auf den erkannten Defiziten der bestehenden Klimaregelung (Altsystem), Anforderungen an den Systementwurf für das neue System abgeleitet. Dieser wird in den folgenden Kapiteln 5 (Systemsynthese und Analyse) und 6 (Analyse und Bewertung) exemplarisch aufgezeigt.

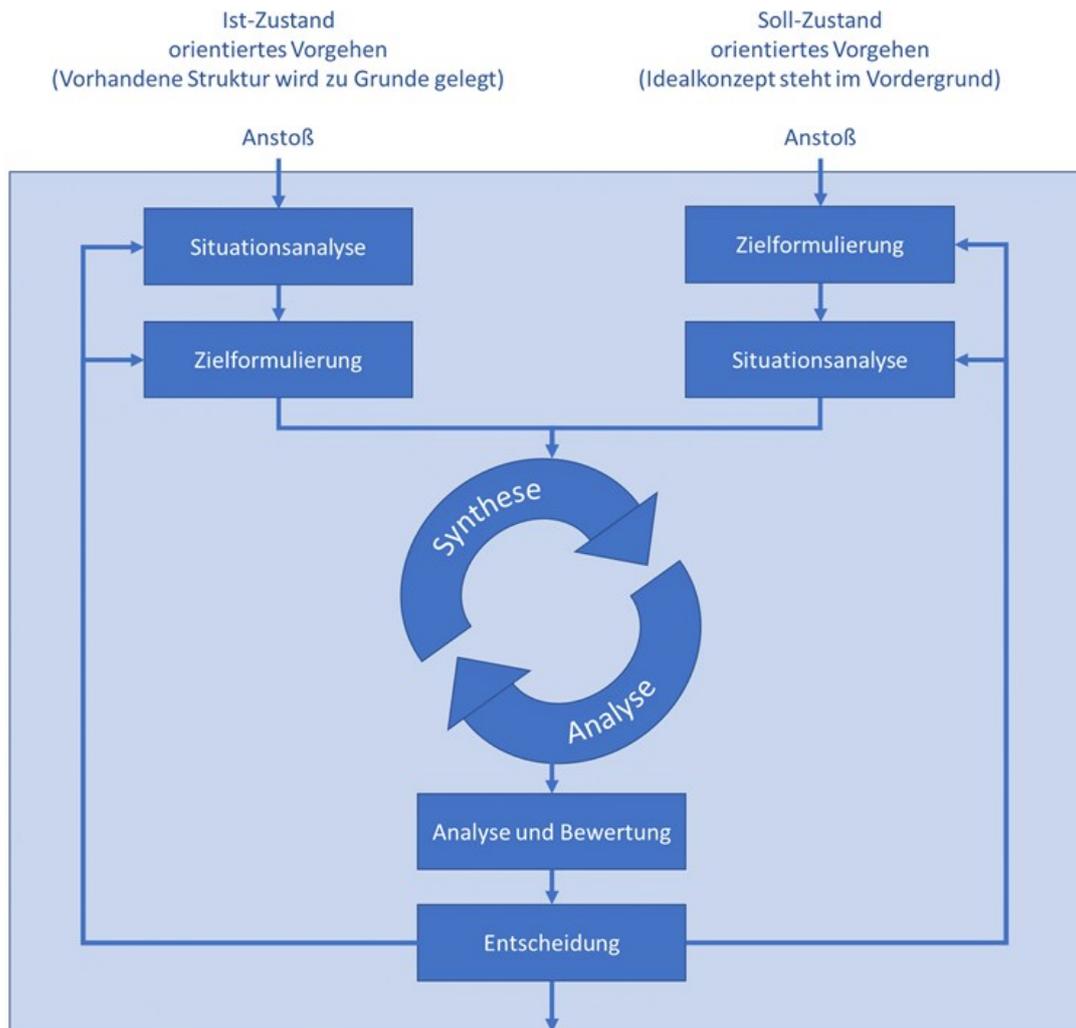


Abbildung 25 Vorgehen im Mikrozyklus gem. VDI Richtlinie 2206

4.1 Konventionelle Modellbildung

Das Modell des Heizungs-, Lüftungs- und Klimaanlage systems und der Fahrzeugkabine wurde im Rahmen des Projektes KISEL [112] in Zusammenarbeit mit der TLK-Thermo GmbH erstellt. Eine ausführliche Beschreibung der Modellierungsmethodik und Durchführung der Modellierung wird in der noch unveröffentlichten Dissertation von Lempp [113] und in [114] beschrieben. Auf diesen Arbeiten basiert das folgende Unterkapitel.

Das Modell wurde in der Simulationsumgebung Dymola mit der Modellierungssprache Modelica, der Modelica Standard Library und der Modellbibliothek TIL Suite [115] erstellt. Abbildung 26 zeigt die Grobstruktur des Kühlsystemmodells. Der Kältekreislauf besteht aus einem Spiralverdichter (1), einem hochdruckseitigen externen Luft-Kältemittel-Wärmetauscher als Kondensator (2) mit einem Ventilator (10), einem internen Wärmetauscher (11), einem Expansionselement (3) und dem inneren Wärmetauscher als Verdampfer (4). Im Luftkanal (9) befindet sich eine Temperaturklappe (5), die den vom Lüfter (12) kommenden Luftstrom aufteilt und je nach Betriebspunkt über den Wärmetauscher im Wasser-Glykol-Kreislauf (6) des Heizkreislaufs leitet. Das Medium wird durch einen Hochspannungs-PTC (7) erwärmt und durch eine Pumpe (8) umgewälzt.

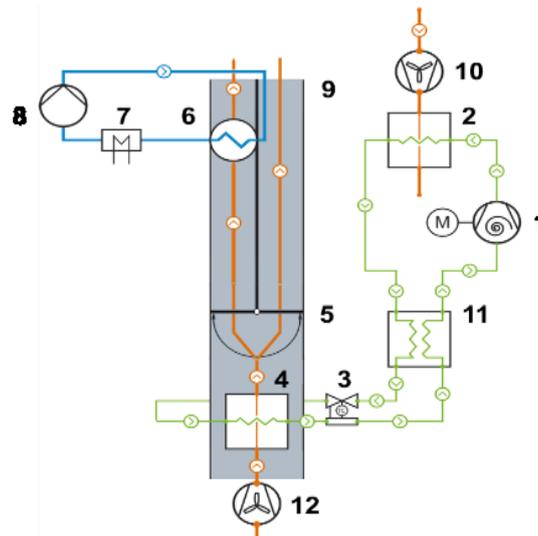


Abbildung 26 Modell des Kältesystems [55]

Der Kühlkreislauf wird mit dem Kältemittel R-1234yf betrieben und besteht aus einem Scroll-Kompressor aus der TIL-Standardbibliothek. Durch die Anpassung des Verdrängungsvolumens und der Kompressor-Effizienz wurde es dem realen Kühlkreislauf des E-Golfs angepasst. Das Modell erfasst den Innendruck und die Reibungsverluste sowie die Wärmeleitung an die Umgebung. Die verwendeten kältemittelseitigen Wärmetauscher stammen aus dem TIL AddOn Automotive [116] und wurden an die Abmessungen der e-Golf-Wärmetauscher angepasst. Die Wärmetauscher wurden über verschiedene Parameter für die Geometrie sowie über Wärmeübertragungs- und Druckverlustbeziehungen an die reale Komponente angepasst. Gemäß [117] wurde für Reynolds-Zahlen über [104] die Korrelation von Dittus/Boelter [118] und für Reynolds-Zahlen unter 2300 die Korrelation von Gnielinski [119] für die Berechnung des kältemittelseitigen Wärmeübergangskoeffizienten für die Fall von turbulenter Strömung verwendet. Die luftseitig erzwungene Wärmeübertragung wurde mit der Korrelation gemäß Haaf [120] bestimmt. Für den kältemittelseitigen Druckverlust während des Phasenwechsels wurde der McAdams-Ansatz [121] in Kombination mit der Swamee/Jain-Formel [122] für Reynolds-Zahlen größer als 2300 auf Basis des homogenen Berechnungsmodells verwendet. Hierbei wurde die Um-

setzung des luftseitigen Druckverlustes vernachlässigt. Die Geometrie der Wärmetauscher wurde vollständig an die der Originalkomponenten angepasst. Zur dreidimensionalen Analyse des Wärmetauschers wurde dieser in einzelne Zellen unterteilt. Der Hochspannungs-PTC wurde über eine Wärmequelle implementiert, die einen verlustfreien Wärmefluss auf ein Rohrmodell überträgt. Das Kühlmittel, das den Wärmefluss des PTC mit einem definierten Wärmeübergangskoeffizienten absorbiert, wird durch dieses Rohrmodell geleitet. Das Expansionselement wurde als thermostatisches Expansionsventil modelliert. Das Öffnungsverhalten des Ventils wurde basierend auf Herstellerdaten im Modell implementiert. Die nominalen Hoch- und Niederdruckwerte betragen 9,7 bar bei 235 cm³/h und 3,7 bar bei 160 cm³/h. Der maximale Betriebspunkt beträgt 7 bar bei 35 °C. Die Lüfter sind als einfache Modelle implementiert, die einen definierten Luftvolumenstrom fördern. Da keine zuverlässigen luftseitigen Messdaten verfügbar waren, wurden keine luftseitigen Druckverluste integriert.

Das Innenmodell des Fahrzeugkabinensystems basiert auf einem ideal gemischten nulldimensionalen Luftvolumen für feuchte Luft. Das Luftvolumen ist hierbei thermisch an Passagiere und die umgebenden Oberflächen der Karosseriewände, Fenster, Boden, Dach und Armaturenbrett sowie Sitze gekoppelt. Diese Umgebungsflächen sind wiederum an die Umwelt gekoppelt (vgl. Abbildung 27). Die Oberflächenelemente wurden unter Verwendung von Parametern für Geometrie, Materialeigenschaften und Wärmeübertragungsbeziehungen implementiert.

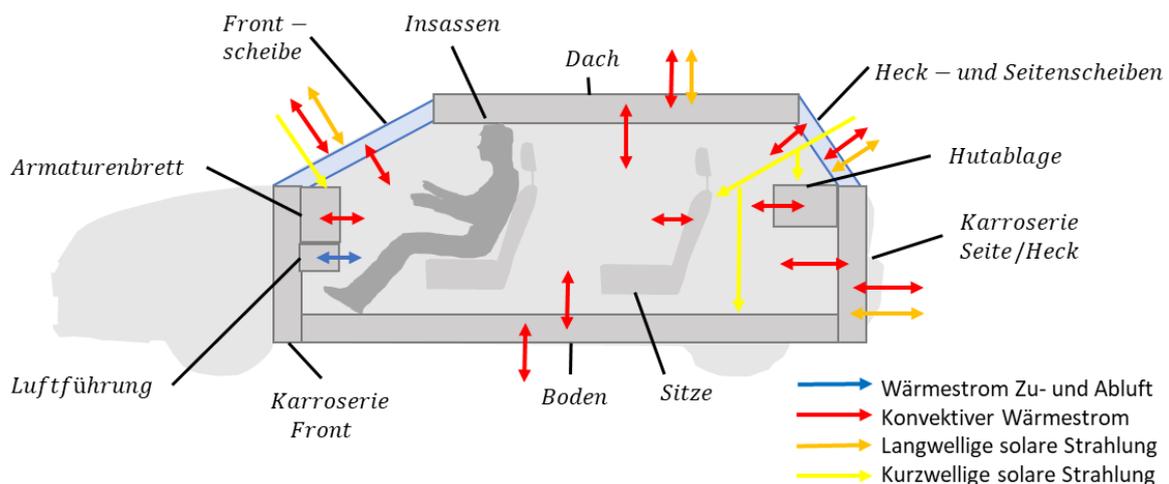


Abbildung 27 Kopplung der Wärmeströme im Innenmodell des Fahrzeugkabinensystems

Der Luftkanal wurde mit einem in TIL erhältlichen Rohrmodell modelliert und thermisch mit der Unterseite des Armaturenbretts gekoppelt. Zur Abbildung des Einflusses der Passagiere wurde hierfür eine zusätzliche Wärme- und Feuchtigkeitsquelle in das Modell integriert. Anhang A.1 zeigt das Modell des Heizungs- und Klimaanlage systems und der Fahrzeugkabine in Modelica.

Für die Regelung des Heizungs-, Lüftungs- und Klimaanlage systems wurde die Verdichter- und HV-Regelung gemäß Kapitel 3.4 in das Modell integriert. Die Eingangsgrößen des Modells unterteilen sich in Stör- und Stellgrößen. In Tabelle 4 sind die Ein- und Ausgangsgrößen des Modells dargestellt.

Das Modell wurde mit mehreren Messläufen kalibriert. Da das Klimatisierungssystem die Innentemperatur als zentralen Referenzwert verwendet, ist die Abbildungsgenauigkeit des Innentemperaturwertes ein zentrales Qualitätskriterium für das Modell. Aufgrund des nulldimensionalen Ansatzes der

idealen Vermischung des gesamten Luftvolumens können kleine Temperaturänderungen entsprechend der real gemessenen Sensorwerte nicht exakt reproduziert werden.

Typ	Bezeichnung	Einheit	Kurzbezeichner
Störgröße	Umgebungstemperatur	K	T_u
	rel. Außenluftfeuchte	%	ϕ_u
	Strahlungsleistung direkt	W/m ²	$P_{sol,dir}$
	Strahlungsleistung diffus	W/m ²	$P_{sol,diff}$
	Fahrzeuggeschwindigkeit	km/h	v
Stellgröße	Solltemperatur der Luft nach Verdampfer	°C	$T_{ev,soll}$
	Solltemperatur Innenraum	°C	T_{soll}
	Zustand ACC (ein/aus)	-	ACC
	Vorlauftemperatur PTC	°C	T_{PTC}
	Umluftklappenstellung (0 bis 1)	-	u
	Gebälsestufe (1 bis 7)	-	G
	Stellung Temperaturklappe (0 bis 1)	-	tk
Ausgangsgröße	Leistung an Verdichterwelle	W	$P_{Verdichter}$
	Leistung PTC	W	P_{PTC}
	Gebälseleistung	W	P_{Gebel}
	Temperatur Innenraum	°C	T_I
	Temperatur Frontscheibe	°C	T_S
	Relative Luftfeuchte Innenraum	%	ϕ_u
	Nachlauftemperatur PTC	°C	T_{PTC}
	Ausblasttemperatur HVAC	°C	T_{aus}
	Temperatur der Luft nach Verdampfer	°C	T_{ev}

Tabella 4 Ein- und Ausgangsgrößen des Gesamtmodells

Das durchschnittliche Heiz- und Abkühlverhalten des Innenraums wird jedoch gut abgebildet. Dies führt zu einer maximalen Abweichung der im Straßenversuch ermittelten Temperaturwerte mit denen der Simulation von 4,8 K während der Aufheizphase und 0,9 K im stationären Zustand über alle ausgewerteten Testläufe.

Das resultierende Modell des Heizungs- und Klimaanlage systems und der Kabine besteht aus 9947 abhängigen Parametern, 468 kontinuierlichen Zeitzuständen, 199 linearen Gleichungssystemen mit höchstens 2. Ordnung, 32 nichtlinearen Gleichungssystemen mit höchstens 1. Ordnung. Die durchschnittliche Berechnungsdauer beträgt 394 Sekunden für 1800 simulierte Sekunden auf einem Intel i7-8700 CPI mit 3,2 GHz.

Zur Verwendung des Modells innerhalb der Matlab-Simulink Simulationsumgebung wurde dieses als Functional Mock-Up Unit (FMU) exportiert. Die FMU enthält die lokalen Solver für die Gleichungssysteme und implementiert eine Co-Simulation-Schnittstelle des FMI-Standards (Functional Mockup Interface) [123]. Über einen Matlab-Simulink-FMU-Block wurde das Modell in das Gesamtmodell integriert. Anhang A.1 zeigt das zur Situationsanalyse eingesetzte Gesamtmodell. Die Heizungsteuerung sowie Klima-/ Innentemperatur-/ Ausströmtemperatur-/ Lüfter- und Umluftklappenregelung (vgl. Kapitel 3.4) der konventionellen Regelung wurden in den Funktionen Heizen, Kühlen, Gebläse und Umluft realisiert und über Matlab-Funktionsblöcke in die Gesamtsimulation integriert. Im Rahmen dieser Arbeit wird nur der erste Mikrozyklus im Makrozyklus durchlaufen. Hierbei werden zunächst die

Funktionen Heizen und Kühlen untersucht. Die Funktion Entfeuchten wird hierbei innerhalb dieser Funktionen realisiert. Da die Funktionen Gebläse und Umluft nicht untersucht werden, werden die Stellgrößen der Umluft- und Gebläseregelung auf konstante Werte eingestellt. Die Testumgebung zur Situationsanalyse des ersten Mikrozykluses besteht demnach aus den Simulink-Blöcken Gebläse und Umluft, dem FMU-Block sowie den Fahrzeugumgebungsbedingungen, welche über die in Anhang A.2 dargestellten Schnittstellen eingespeist werden. Das Testobjekt zur Situationsanalyse ist in den Simulink-Blöcken Heizen und Kühlen umgesetzt.

4.2 Situationsanalyse

4.2.1 Design of Experiment

Das Ziel des Einsatzes der modellprädiktiven Regelung auf Basis maschinellen Lernens zur Klimatisierung von Elektrofahrzeugen ist es, die Anforderungen gem. Kapitel 3.2 an die konventionellen Regelung des Heizungs-, Lüftungs- und Klimaanlage-Systems bei einem verringerten Energiebedarf zu erreichen bzw. bei begrenztem Energiebudget die Regelgüte des Systems zu maximieren. Hierbei wird zunächst ein Ausschnitt der Gesamtanforderungen an das Teilsystem der Regelung des Heizungs- und Klimaanlage-Systems für ein batterieelektrisches Fahrzeug im vorkonditionierten Zustand betrachtet. Testobjekt des ersten Mikrozyklus ist die in den Simulink-Blöcken Heizen und Kühlen umgesetzte Regelung des HLK-Systems durch Einstellung der Position der Temperaturklappe und Schalten des Zustandes des Kühlkreislaufs. Die zu betrachtenden funktionalen und nichtfunktionalen Anforderungen an das Regelungssystem zum Anstoß des ersten Mikrozyklus werden gemäß Tabelle 5 definiert.

Nr.	Anforderung
1.	Die Regelung des Heizungs- und Klimaanlage-System soll bei allen relevanten Umgebungsbedingungen für das klimatische Cluster Gesamteuropa gem. FAT Studie 224 [110] eine komfortable Innentemperatur T_{Ist} gem. DIN 1946-3 für die Insassen einstellen.
2.	Die Regelung des Heizungs- und Klimaanlage-System muss bei allen relevanten Umgebungsbedingungen für das klimatische Cluster Gesamteuropa gem. FAT Studie 224 [110] eine Innentemperatur T_{Ist} von mind. 15 °C einstellen.
3.	Die Regelung des Heizungs- und Klimaanlage-System muss bei allen relevanten Umgebungsbedingungen für das klimatische Cluster Gesamteuropa gem. FAT Studie 224 [110] eine Innentemperatur T_{Ist} von max. 30 °C einstellen.
4.	Die Regelung des Heizungs- und Klimaanlage-System muss bei allen relevanten Umgebungsbedingungen für das klimatische Cluster Gesamteuropa gem. FAT Studie 224 [111] eine relative Luftfeuchtigkeit φ unter 80% einstellen.
5.	Die Regelung des Heizungs- und Klimaanlage-System muss die Beschlagsfreiheit sicherstellen. Hierbei darf ein Taupunktabstand $\tau_{Abstand}$ von 1,5 K nicht unterschritten werden.

Tabelle 5 Betrachtende funktionale und nichtfunktionale Anforderungen an das Regelungssystem

Zur Überprüfung der Anforderungen werden im Folgenden die Metriken und Zielwerte gemäß Tabelle 6 und zur Bewertung der Energieeffizienz die Metriken gemäß Tabelle 7 verwendet.

Nr.	Bewertungsgröße	Metrik	Zielwerte
1.	Innentemperatur	$J_T = \sqrt{\frac{1}{t} \sum_{i=1}^{i=t} (T_{Ist}(i) - T_{Soll}(i))^2}$	$J_T \leq 1$
2.	Innentemperatur	$J_{T\ OG} = \sqrt{\frac{1}{t} \sum (T_{Ist}(T_{Ist} > 30) - 30)^2}$	$J_{T\ OG} = 0$
3.	Innentemperatur	$J_{T\ UG} = \sqrt{\frac{1}{t} \sum (T_{Ist}(T_{Ist} < 15) - 15)^2}$	$J_{T\ UG} = 0$
4.	relative Luftfeuchtigkeit	$J_{\varphi\ 80} = \sqrt{\frac{1}{t} \sum (\varphi(\varphi > 80) - 80)^2}$	$J_{\varphi\ 80} = 0$
5.	Beschlagsfreiheit	$J_{\tau_{Abstand}} = \sqrt{\frac{1}{t} \sum (\tau_{Abstand}(\tau_{Abstand} < 1,5) - 1,5)^2}$	$J_{\tau_{Abstand}} = 0$

Tabelle 6 Metriken zur Überprüfung der Anforderungen

Die Metrik Nr. 1 entspricht der L²-Norm als Maß der Regelgüte der Regelungstechnik. Die Metriken Nr.2 - Nr.5 bestimmen das Ausmaß der Verletzung der Anforderungen nach Tabelle 5. Die Metriken Nr.7 - Nr.8 bestimmen die mittlere Leistung der Aggregate bzw. des Gesamtsystems.

Nr.	Bewertungsgröße	Metrik
7.	Leistung Verdichter	$J_{PV} = \frac{1}{t} \sum_{i=1}^{i=t} P_v(i)$
8.	Leistung Hochspannungs-PTC	$J_{PPTC} = \frac{1}{t} \sum_{i=1}^{i=t} P_{PTC}(i)$
9.	Gesamtleistung	$J_P = J_{PV} + J_{PPTC}$

Tabelle 7 Metriken zur Bewertung der Energieeffizienz

Zur Überprüfung der Anforderungen der konventionellen Regelung sowie der Bewertung der Energieeffizienz werden Versuche durch Simulation am Gesamtmodell durchgeführt und hierfür die definierten Metriken ausgewertet. Hierbei werden für jedes Versuchsszenario unterschiedliche Umgebungsbedingungen definiert. Zur Vergleichbarkeit der Ergebnisse erfolgt die Untersuchung am auf 22 °C und 50 % relativer Luftfeuchte vorkonditionierten Fahrzeug. Das Modell wird zum Simulationsbeginn jeweils mit den gleichen Startwerten initialisiert. Als Geschwindigkeitsprofil wird der in Abbildung 28 dargestellte Prüfzyklus WLTC (Worldwide Harmonized Light Duty Test Cycle) der Klasse 2 verwendet.

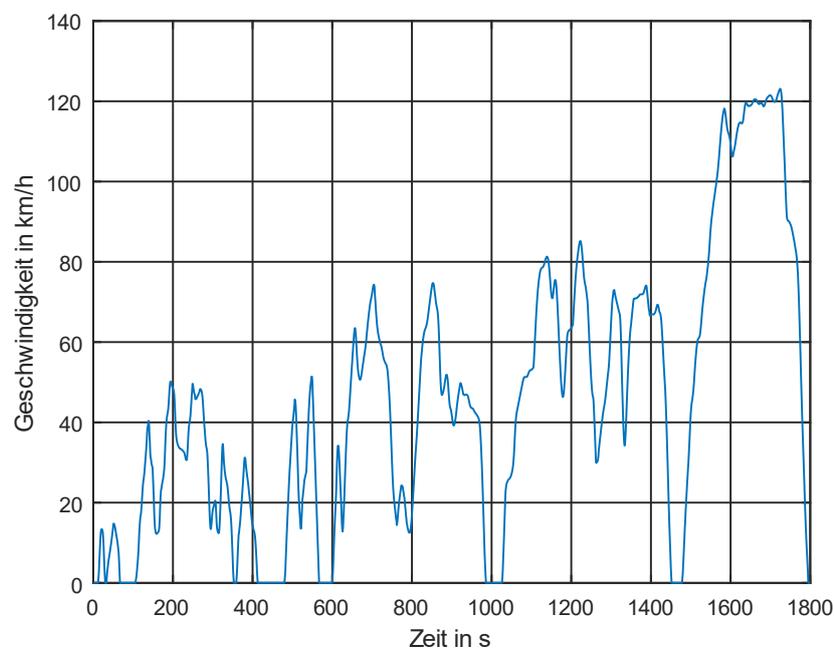


Abbildung 28 Geschwindigkeitsprofil gem. Prüfzyklus WLTC Klasse 2

Die Umgebungsbedingungen der einzelnen Versuchsszenarien unterscheiden sich in den klimatischen Umgebungsbedingungen der Umgebungstemperatur, der Umgebungsluftfeuchte und der Sonnenein-

strahlung. Während für die Überprüfung der Anforderungen eines Heizungs-, Lüftungs- und Klimaanlage eines PKWs vor allem extreme äußere Betriebsbedingungen in Form von Extremwerten der Umgebungstemperatur, Umgebungsluftfeuchte und Sonneneinstrahlung relevant sind, sind für die Bewertung der Energieeffizienz eher die der Nutzung entsprechenden Klimabedingungen von Interesse. Hierfür wurden von Strupp und Lemke in einer umfangreichen Recherche (vgl. [111]) die möglichen Kombinationen von Temperatur, Luftfeuchte und Sonneneinstrahlung in Klimacustern zusammengefasst und hierfür, für jeweils verschiedene Regionen, die Nutzungshäufigkeit von PKW ermittelt und zusammengefasst. Auf Basis dieser Daten kann für jedes Klimacuster ein Energiebedarf einer Pkw-Kälte-/Heizanlage ermittelt werden und über die Nutzungshäufigkeit (und damit Eintrittswahrscheinlichkeit des Klimacusters) der durchschnittliche Energiebedarf über einen Jahresverlauf abgeschätzt werden. Die Klimacuster der FAT Studie 224 unterscheiden sich durch die Außentemperaturbereiche von -50 °C bis +50 °C in 5°-Schritten, die Luftfeuchtebereiche von 0 % bis 100 % in 20 %-Schritten, sowie 4 Bereiche der solaren Strahlungsleistung (0-100 W/m², 100-400 W/m², 400-900 W/m² und +900W/m²). In Anhang A.3 ist die prozentuale relative Eintrittswahrscheinlichkeit für die einzelnen Cluster dargestellt. Im Rahmen dieser Arbeit dienen die 192 Klimacuster von -25 °C bis +35 °C mit 20 % bis 100% rel. Luftfeuchte als Basis zur Erstellung der Versuchsszenarien für die Situationsanalyse. In Tabelle 8 sind diese Klimacuster mit ihrer aus der FAT Studie 224 abgeleiteten absoluten Auftrittshäufigkeit dargestellt.

0 W/m ² < ψ ψ < 100 W/m ²	-25°C- -20°C	-20°C - -15°C	-15°C- -10°C	-10°C - -5°C	-5°C- 0°C	0 °C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C
20 < φ ≤ 40	0,00%	0,00%	0,00%	0,00%	0,01%	0,03%	0,08%	0,16%	0,20%	0,22%	0,18%	0,05%
40 < φ ≤ 60	0,00%	0,00%	0,01%	0,03%	0,15%	0,59%	1,25%	1,71%	1,54%	1,08%	0,40%	0,04%
60 < φ ≤ 80	0,00%	0,01%	0,05%	0,31%	1,35%	3,43%	4,98%	4,22%	2,60%	0,96%	0,15%	0,00%
80 < φ ≤ 100	0,02%	0,07%	0,28%	0,96%	3,00%	5,13%	4,96%	2,79%	1,14%	0,20%	0,01%	0,00%
100 W/m ² < ψ ψ < 500 W/m ²	-25°C- -20°C	-20°C - -15°C	-15°C- -10°C	-10°C - -5°C	-5°C- 0°C	0 °C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C
20 < φ ≤ 40	0,00%	0,00%	0,00%	0,00%	0,01%	0,07%	0,26%	0,65%	0,94%	0,99%	0,76%	0,27%
40 < φ ≤ 60	0,00%	0,00%	0,00%	0,02%	0,15%	0,75%	2,04%	3,40%	4,07%	3,09%	1,16%	0,15%
60 < φ ≤ 80	0,00%	0,00%	0,02%	0,12%	0,59%	1,84%	3,45%	4,55%	4,08%	1,69%	0,26%	0,01%
80 < φ ≤ 100	0,00%	0,01%	0,04%	0,08%	0,24%	0,55%	0,92%	1,23%	0,89%	0,21%	0,02%	0,00%
500 W/m ² < ψ ψ < 900 W/m ²	-25°C- -20°C	-20°C - -15°C	-15°C- -10°C	-10°C - -5°C	-5°C- 0°C	0 °C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C
20 < φ ≤ 40	0,00%	0,00%	0,00%	0,00%	0,00%	0,03%	0,14%	0,51%	1,03%	1,44%	1,31%	0,54%
40 < φ ≤ 60	0,00%	0,00%	0,00%	0,00%	0,01%	0,08%	0,34%	1,12%	2,36%	2,50%	1,23%	0,21%
60 < φ ≤ 80	0,00%	0,00%	0,00%	0,00%	0,01%	0,03%	0,10%	0,33%	0,61%	0,35%	0,08%	0,01%
80 < φ ≤ 100	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,01%	0,01%	0,00%	0,00%	0,00%
ψ < 900 W/m ²	-25°C- -20°C	-20°C - -15°C	-15°C- -10°C	-10°C - -5°C	-5°C- 0°C	0 °C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C
20 < φ ≤ 40	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,01%	0,06%	0,17%	0,22%	0,10%
40 < φ ≤ 60	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,02%	0,06%	0,13%	0,10%	0,02%
60 < φ ≤ 80	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,01%	0,01%	0,00%	0,00%
80 < φ ≤ 100	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%

Tabelle 8 Prozentuales Auftreten der Klimacuster für Gesamteuropa in Anlehnung an [111]

Für die Situationsanalyse werden drei Versuchsreihen durchgeführt. Jedes Versuchsszenario wird fortlaufend durchnummeriert. Da drei Versuchsreihen mit je 192 Versuchsszenarien durchgeführt werden, werden den einzelnen Szenarien die Nummern 1-576 zugeordnet. Anhang A.4 zeigt die Zuordnung der einzelnen Versuchsszenarien zu den jeweiligen Klimacustern.

In der ersten Versuchsreihe wird für jedes der 192 Klimacuster der zeitliche Verlauf der Umgebungsgrößen anhand der Mittelwerte der Klimacuster statisch konstruiert und hierfür eine Simulation mit konventioneller Regelung im Prüfzyklus WLTC durchgeführt.

In der zweiten Versuchsreihe werden die Versuchsszenarien mit dynamischen Schwankungen der Umgebungsgrößen über den Verlauf der simulierten Fahrten durchgeführt. Zur Nachbildung der dynamischen Schwankungen der Umgebungsgrößen wurden Messwerte aus realen Straßenversuchen verwendet. Für jeden Bereich der solaren Strahlungsleistung wurden Messsignale aus einem Straßenversuch mit ähnlichem Mittelwert verwendet und dieses auf den Mittelwert des Bereichs skaliert. Da Luftfeuchte und Umgebungstemperatur mit der solaren Strahlungsleistung korrelieren, wurden diese Signale aus dem Verlauf des geglätteten Strahlungsverlaufs konstruiert. Hierzu wurden zunächst die maximalen Differenzen des Verlaufs der Umgebungstemperatur und der Luftfeuchtigkeit für einen Zeitraum von 1800 Sekunden aus allen Straßenversuchen ermittelt. Für die Außentemperatur ergibt sich eine maximale Differenz von 3.57 K und für die rel. Außenluftfeuchte 2.68 %¹³. Das Signal des geglätteten Strahlungsverlaufs wurden anschließend für jedes Klimacluster auf die Mittelwerte der Cluster und die maximalen Differenzen der Umgebungsgrößen skaliert. Abbildung 29 zeigt für das Versuchsszenario Nr. 199 mit einer Strahlung zwischen 0 W/m² bis 100 W/m², einer Umgebungstemperatur zwischen 5 °C bis 10 °C und einer rel. Luftfeuchte zwischen 20% bis 40%, die konstruierten Verläufe der solaren Strahlungsleistung und der Umgebungstemperatur sowie die resultierenden Verläufe der Stellgrößen und Leistungen der Nebenaggregate (vgl. Anhang A.4).

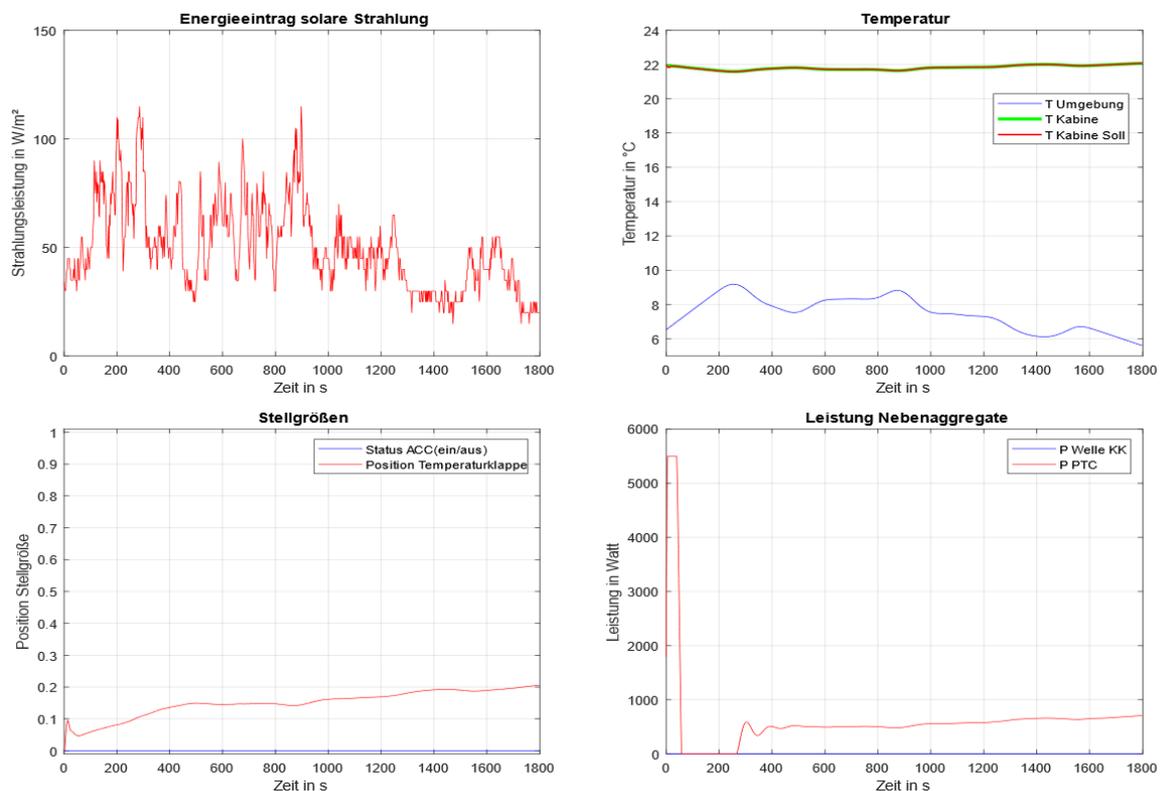


Abbildung 29 Auswahl von Ein- und Ausgangsgrößen des Versuchsszenarios Nr. 199

In der dritten Versuchsreihe werden die Auswirkungen des Verhaltens des konventionellen Reglers bei begrenztem Energiebudget untersucht. Hierfür werden die Umgebungsbedingungen der ersten Versuchsreihe übernommen. Bei Überschreiten eines Energiebudgets von 1,1 kWh wird die Regelung deaktiviert.

¹³ Da die Straßenversuche überwiegend auf der Strecke Goslar - Clausthal Zellerfeld durchgeführt wurden, sind die ermittelten Werte nur für diese Strecke repräsentativ.

Die drei Versuchsreihen mit jeweils 192 Versuchsszenarien für jedes Klimacluster führen zu 576 durchzuführenden Versuchsszenarien. Für jedes Versuchsszenario werden die Metriken gem. Tabelle 6 und Tabelle 7 ausgewertet.

4.2.2 Bewertung der konventionellen Regelung

4.2.2.1 Bewertung der Abweichung von Soll- und Ist-Kabinentemperatur

Die Bewertung der Abweichungen von Soll- und Ist-Kabinentemperatur erfolgt im Folgenden an Hand der Zielwerte nach Auswertung der Metrik Nr.1 gemäß Tabelle 6 für sämtliche Versuchsszenarien separat für jede der drei Versuchsreihen. Die zusammengefasste Auswertung für die drei Versuchsreihen ist in Anhang A.5 tabellarisch aufgeführt.

Versuchsreihe I - Statischer Verlauf der Umgebungsbedingungen (Versuchsszenarien Nr. 1-192)

Der Zielwert der Metrik Nr.1 wurde in 176 der 192 Versuchsszenarien erreicht. Die akkumulierte Eintrittswahrscheinlichkeit dieser Szenarien beträgt gem. Tabelle 8 98,49%. In Abbildung 30 sind Temperatur- und Stellgrößenverläufe bei kalten Umgebungsbedingung am Beispiel des Versuchsszenario Nr.2 dargestellt. Die Leistungsaufnahme des PTC-Heizelements steigt zu Beginn des Szenarios auf den Maximalwert. Der innere HV-Heizungsregler regelt hierbei die SOLL-Nachlauftemperatur ausgehend vom vorkonditionierten Zustand ein. Die PID-Kabinentemperaturregelung reagiert auf die initiale Abweichung der vorkonditionierten Kabinentemperatur und der SOLL-Kabinentemperatur durch Erhöhung der Temperaturklappenstellung und schwingt sich nach einer transienten Phase von ca. 400 Sekunden auf den stationären Zustand ein. Hierbei wird die Soll-Temperatur um maximal 0,1 K überschritten. Der Sollwert der Regelgröße Kabinentemperatur wird nach ca. 60 Sekunden bei sehr geringer Überschwingung erreicht.

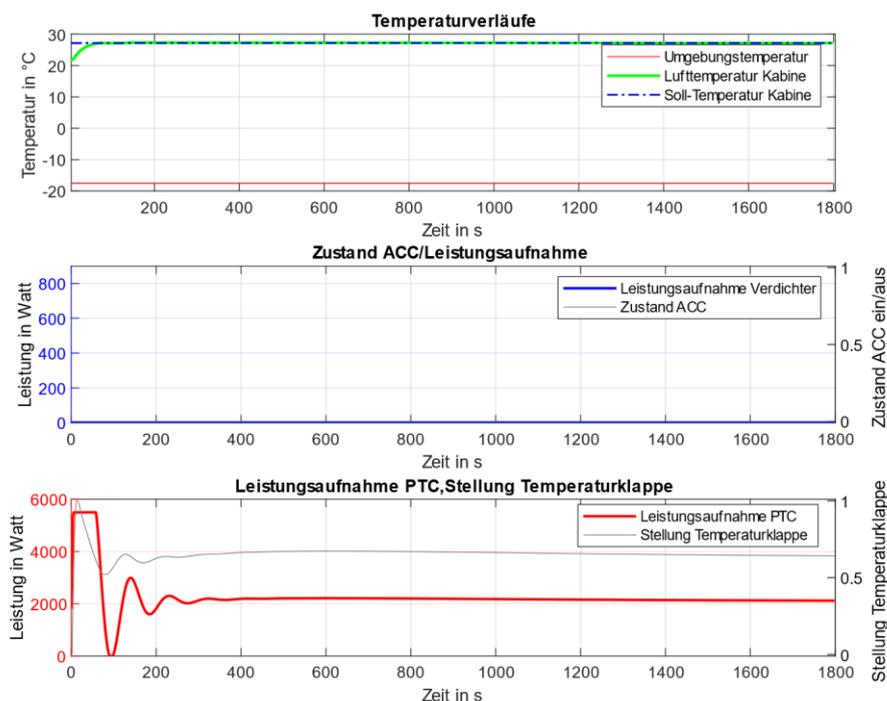


Abbildung 30 Temperatur- und Stellgrößenverläufe im Versuchsszenario Nr. 2

In Abbildung 31 sind Temperatur- und Stellgrößenverläufe bei heißen Umgebungsbedingungen am Beispiel des Versuchsszenario Nr. 12 dargestellt. Der Sollwert der Kabinentemperatur (vgl. Abbildung

16) liegt zum Start des Szenarios dicht an der vorkonditionierten Kabinentemperatur. Der Mehrpunkt-Klimaregler gleicht die thermische Last der hohen Außentemperatur durch Schalten der Verdichterregelung aus. Die Leistungsaufnahme des Verdichters folgt dem Zustand des ACCs und schwingt dementsprechend kontinuierlich mit. Die Kabinentemperatur folgt diesem Verlauf und schwingt kontinuierlich leicht um den Sollwert. Hierbei wird die Soll-Temperatur um maximal 0,9 K überschritten bzw. um maximal 0,2 K unterschritten.

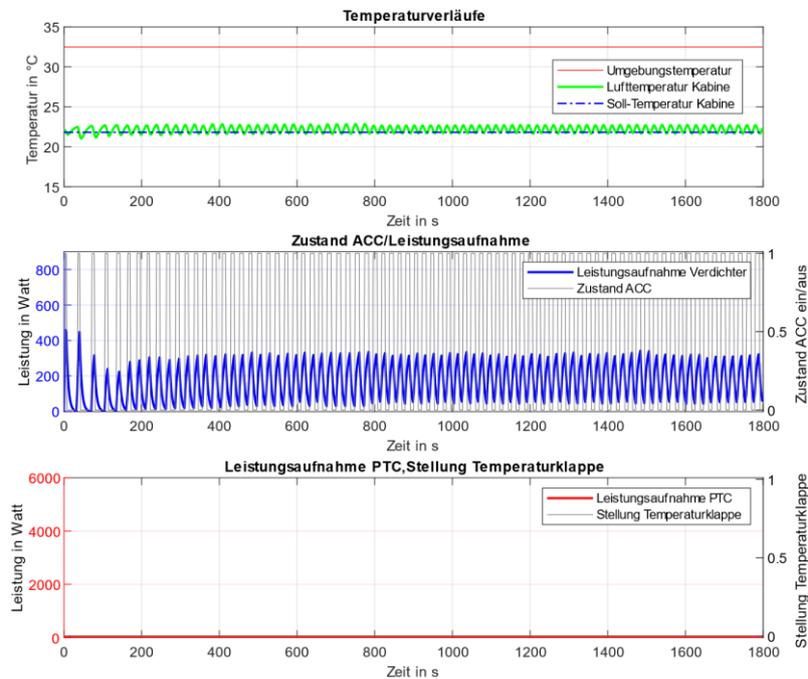


Abbildung 31 Temperatur- und Stellgrößenverläufe im Versuchsszenario Nr. 12

Abbildung 32 zeigt Temperatur- und Stellgrößenverläufe bei moderaten Umgebungsbedingungen am Beispiel des Versuchsszenarios Nr. 44.

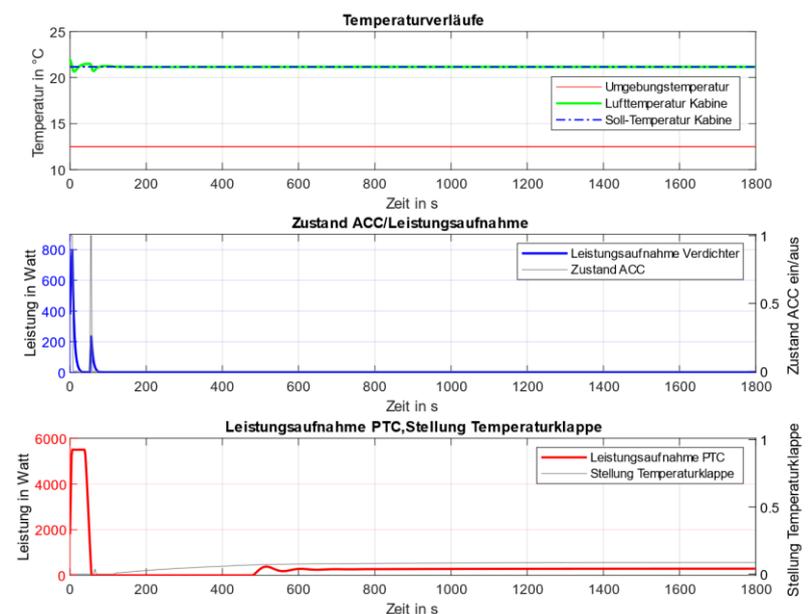


Abbildung 32 Temperatur- und Stellgrößenverläufe im Versuchsszenario Nr. 44

Hierbei sind sowohl die Funktionen Heizen durch die PID-Kabinentemperaturregelung und die Funktion Kühlen durch den Mehrpunkt-Klimaregler aktiv. Der Sollwert der Kabinentemperatur liegt initial ebenfalls dicht an der vorkonditionierten Kabinentemperatur. Der HV-Heizungsregler regelt zunächst die SOLL-Nachlaufzeit im Heizkreislauf ausgehend vom vorkonditionierten Zustand ein. Da die Kabinentemperatur aber leicht über bzw. am Sollwert liegt, schließt die PID-Kabinentemperaturregelung die Temperaturklappe, so dass dem Heizkreislauf zunächst keine Wärmeleistung entnommen wird. Der Klimaregler gleicht zunächst die initial etwas zu warme Kabinentemperatur durch zweimaliges Schalten der Verdichterregelung aus. Das Entgegenwirken von Heiz- und Kühlleistung wird durch die Hysteresen im Mehrpunkt-Klimaregler und in der Kabinentemperaturregelung verringert, kann aber nicht vollständig verhindert werden. Nach dem Unterschreiten des Sollwertes der Kabinentemperatur gleicht die PID-Kabinentemperaturregelung die thermische Last der Umgebungstemperatur durch leichtes Öffnen der Temperaturklappe aus. Dem Heizkreislauf wird dabei Wärme entzogen. Hierdurch verringert sich die Nachlaufzeit im Heizkreislauf, welchem der HV-Heizungsregler durch Erhöhung der Leistung des PTC-Heizelements entgegenwirkt.

In 16 der 192 Versuchsszenarien wurde der Zielwert der Metrik Nr.1 verletzt. Hierbei wurde der Zielwert geringfügig mit 1,44 K bis 2,78 K überschritten. Die akkumulierte Eintrittswahrscheinlichkeit der betroffenen Szenarien mit Zielwertverletzung beträgt gem. Tabelle 8 1,51 %. Die Überschreitung trat ab einer durchschnittlichen solaren Strahlungsleistung von 700 Watt/m² bei gleichzeitiger durchschnittlicher Außentemperatur ab 32,5 °C, sowie ab einer durchschnittlichen solaren Strahlung von 900 Watt/m² bei gleichzeitiger durchschnittlicher Außentemperatur ab 22,5 °C auf. In Abbildung 33 sind Temperatur- und Stellgrößenverläufe bei heißen Umgebungsbedingungen und hoher solarer Strahlung am Beispiel des Versuchsszenarios Nr. 144 dargestellt.

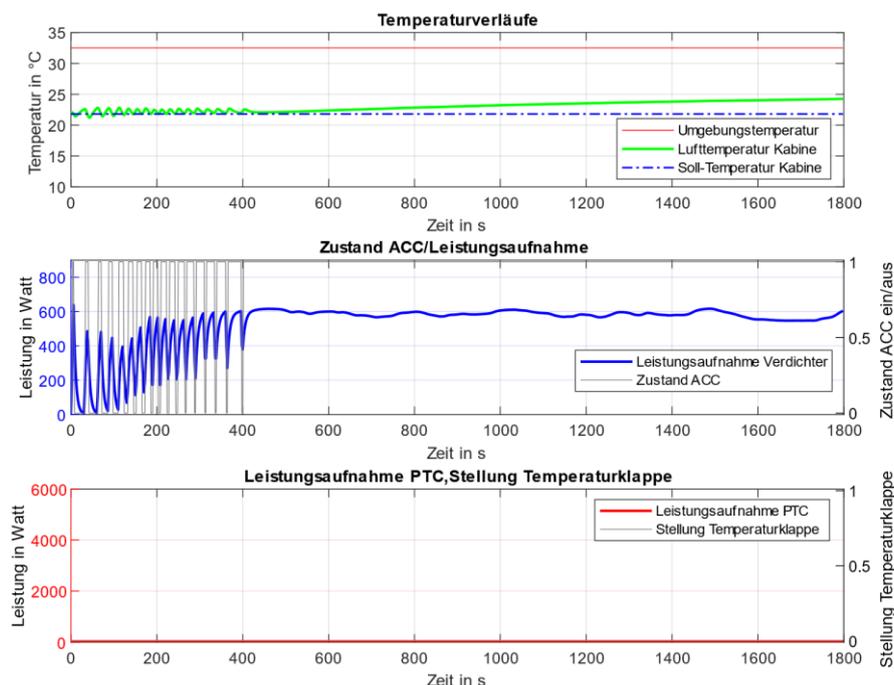


Abbildung 33 Temperatur- und Stellgrößenverläufe im Versuchsszenario Nr. 144

Durch die hohe solare Strahlungsleistung erhöht sich die Temperatur des Interieurs kontinuierlich wodurch dieses wiederum kontinuierlich eine höhere Wärmestrahlung emittiert. Dieser Effekt kann auch durch Abkühlung des zugeführten Luftmassenstrom auf eine Lufttemperatur von 2 °C nach

Verdampfer im Luftpfad nicht mehr kompensiert werden. Da in den Versuchsszenarien die Funktion Gebläse nicht betrachtet wird und die Frischluftgebläseleistung auf einen konstanten Wert eingestellt wird, kann durch die Regelung ein hierfür benötigter höherer Luftmassenstrom nicht eingestellt werden¹⁴. Wie in Abbildung 33 dargestellt, schaltet der Klimaregler ab einem Zeitpunkt von 400 Sekunden nach Start die Verdichterregelung stetig zu. Hierdurch wird die zugeführte Luft bis auf den Minimalwert von 2 °C nach Verdampfer abgekühlt.

Versuchsreihe II - Dynamischer Verlauf der Umgebungsbedingungen (Versuchsszenarien Nr. 193-384)

Der Mittelwert für die Bewertung der Regelgüte nach Metrik Nr. 1 über die 192 Versuchsszenarien der Versuchsreihe I ergibt 0,678 K. Dies bedeutet eine leichte Verschlechterung im Vergleich zur Versuchsreihe I mit einem Mittelwert von 0,503 K. Im Gegensatz zur Versuchsreihe I traten in der Versuchsreihe II in 28 der 192 Versuchsszenarien leichte bis mittlere Verletzungen des Zielwertes der Metrik Nr. 1. Der Zielwert wurde dabei von 1,12 K bis 3,67 K überschritten. Die Verletzungen traten bei einer durchschnittlichen solaren Strahlung von 700 Watt/m² und durchschnittlichen Außentemperaturen von 22,5 °C sowie bei durchschnittlicher solaren Strahlung 900 Watt/m² und durchschnittlichen Außentemperaturen von 17,5 °C auf. Die akkumulierte Eintrittswahrscheinlichkeit der betroffenen Szenarien mit Zielwertverletzung beträgt gemäß Tabelle 8 8,56 %. Abbildung 34 zeigt für eines dieser Szenarien die Temperatur-, Stellgrößen- und Strahlungsverläufe bei heißen Umgebungsbedingung und hoher solarer Strahlung am Beispiel des Versuchsszenarios Nr. 336.

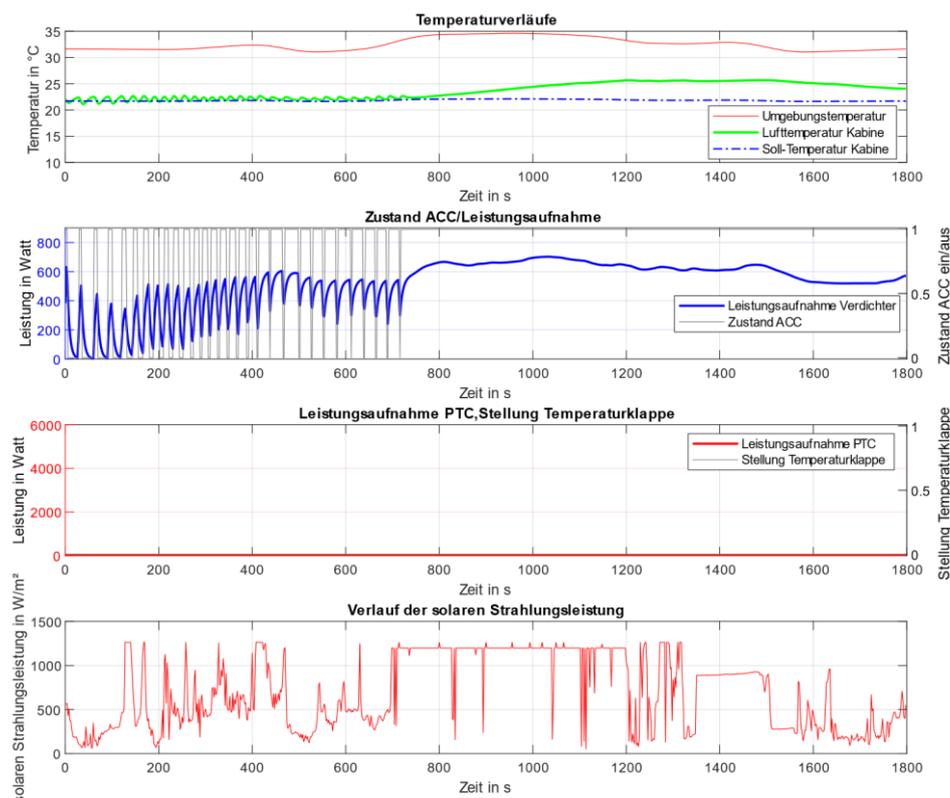


Abbildung 34 Temperatur-, Strahlung- und Stellgrößenverläufe im Versuchsszenario Nr. 336

¹⁴ Die im folgenden Kapitel 5 entworfene modellprädiktive Regelung unterliegt den gleichen Beschränkungen.

Durch den dynamischen Verlauf der solaren Strahlung wird der jeweilige Durchschnittswert der Strahlung deutlich über- bzw. unterschritten. Wie in Abbildung 34 zu erkennen, liegt im Versuchsszenario Nr. 336 die solare Strahlungsleistung bis zu einem Zeitpunkt von ca. 700 Sekunden ab Versuchsstart deutlich unter dem Durchschnittswert von 700 W/m^2 . Bis zu diesem Zeitpunkt kann ein ausreichender Enthalpiestrom eingestellt werden, um die thermische Last auszugleichen und damit die Soll-Kabinentemperatur zu erreichen. Wie im Versuchsszenario Nr. 144 (vgl. Abbildung 33) kann danach aufgrund des zu geringen Massestroms die Strahlungsleistung nicht mehr kompensiert werden.

In den übrigen 164 der 192 Versuchsszenarien der Versuchsreihe II wurde der Zielwert der Metrik Nr. 1 nicht überschritten. Die akkumulierte Eintrittswahrscheinlichkeit dieser Szenarien ohne Zielwertverletzung beträgt gem. Tabelle 8 91,44 %. Das Reglerverhalten bei heißen Umgebungsbedingungen ist vergleichbar mit dem der Versuchsreihe I bei statischen Umgebungsbedingungen. Die Kabinentemperatur schwingt kontinuierlich leicht um den Sollwert und gleicht den dynamischen Verlauf der thermischen Last fast vollständig aus. Abbildung 35 zeigt hierfür beispielhaft die Temperatur-, Stellgrößen- und Strahlungsverläufe des Versuchsszenarios Nr. 336.

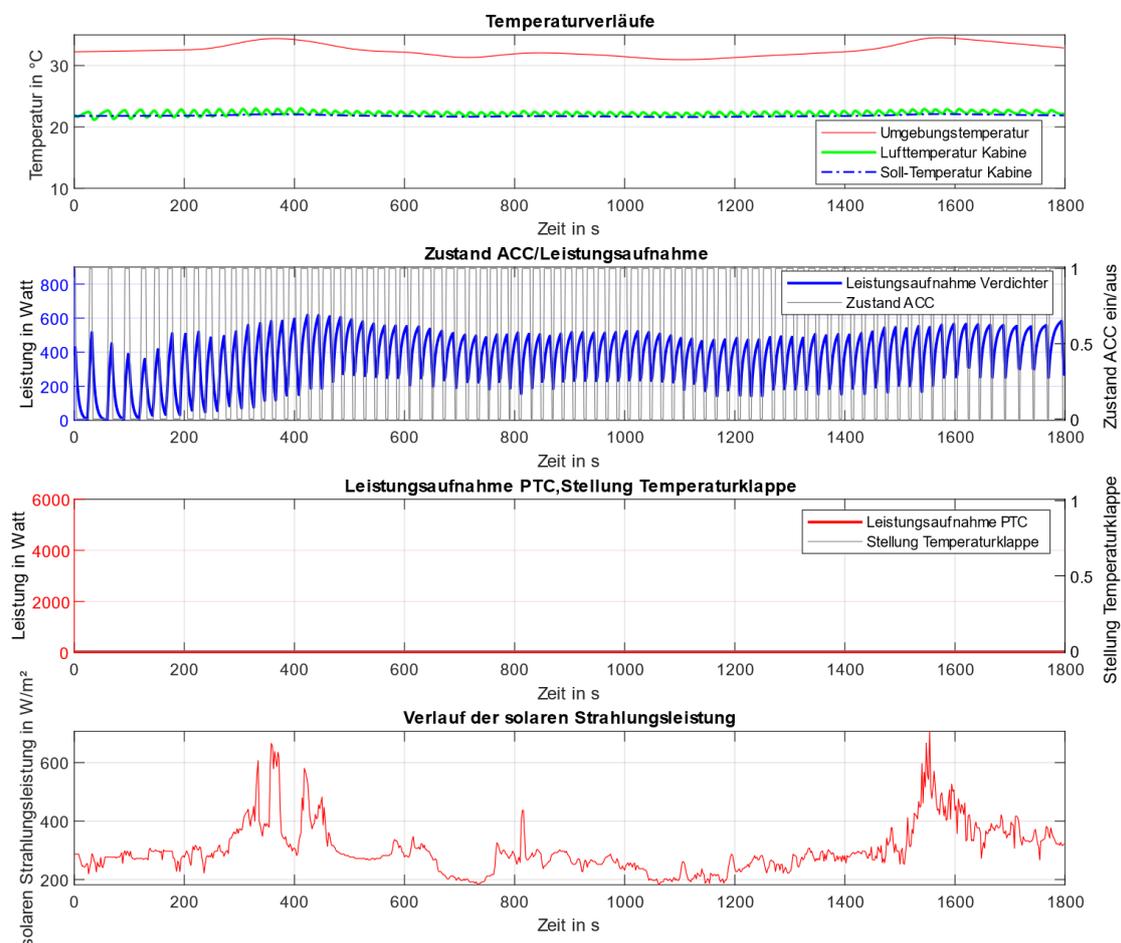


Abbildung 35 Temperatur-, Strahlungs- und Stellgrößenverläufe im Versuchsszenario Nr. 288

Bei kalten Umgebungsbedingungen ist das Reglerverhalten der PID-Kabinentemperaturregelung ebenfalls vergleichbar mit dem der Versuchsreihe I bei statischen Umgebungsbedingungen. Die Kabinentemperatur erreicht nach der Einschwingphase den Sollwert und gleicht den weiteren dynamischen Verlauf der thermischen Last ebenfalls fast vollständig aus. Abbildung 36 zeigt hierfür beispielhaft die Temperatur-, Stellgrößen- und Strahlungsverläufe des Versuchsszenarios Nr. 194.

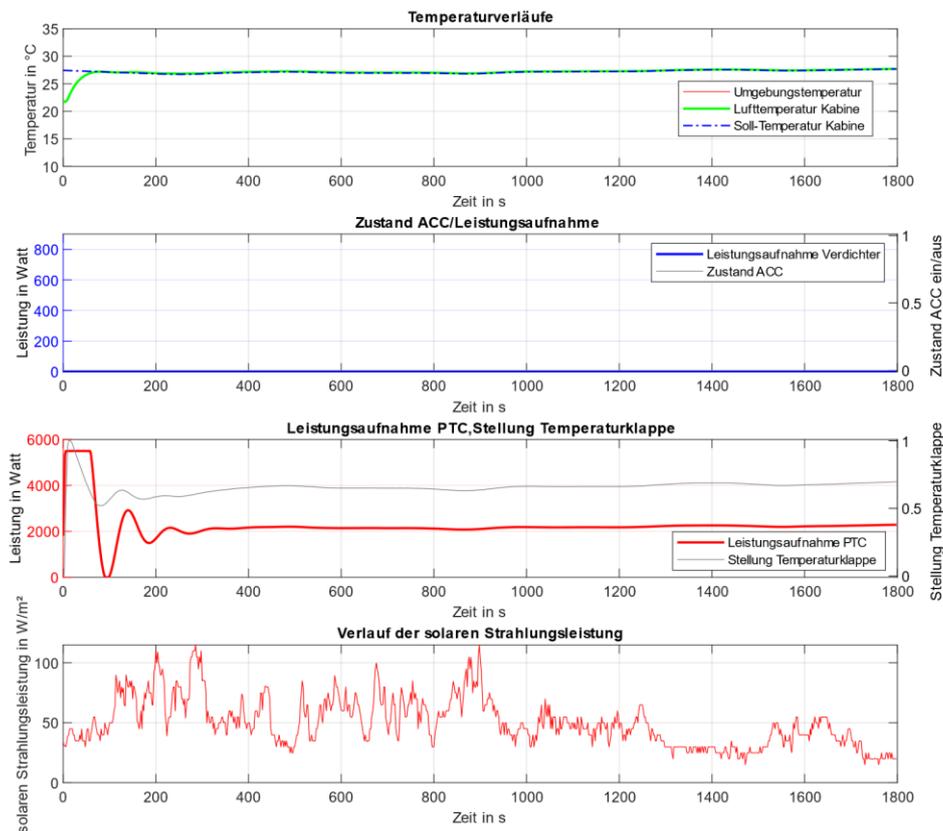


Abbildung 36 Temperatur-, Strahlungs- und Stellgrößenverläufe im Versuchsszenario Nr. 194

Versuchsreihe III - Statischer Verlauf der Umgebungsbedingungen und begrenztes Energiebudget (Versuchsszenarien Nr. 385-576)

In 96 der 192 Versuchsszenarien der Versuchsreihe III wurde der Zielwert der Metrik Nr. 1 überschritten. Die Zielwertüberschreitungen traten bei solaren Strahlungsleistungen unter 300 W/m^2 bis zu einer durchschnittlichen Umgebungstemperatur von $2,5 \text{ }^\circ\text{C}$, bei solaren Strahlungsleistungen über 300 W/m^2 bis zu einer durchschnittlichen Umgebungstemperatur von $-7,5 \text{ }^\circ\text{C}$, ab einer durchschnittlichen solaren Strahlungsleistung von 700 Watt/m^2 bei gleichzeitiger durchschnittlicher Außentemperatur ab $32,5 \text{ }^\circ\text{C}$, sowie ab einer durchschnittlichen solaren Strahlung von 900 Watt/m^2 bei gleichzeitiger durchschnittlicher Außentemperatur ab $22,5 \text{ }^\circ\text{C}$ auf. Die Zielwertüberschreitungen tritt vor allem bei extremen klimatischen, vor allem sehr kalten, Umgebungsbedingungen mit geringen Eintrittswahrscheinlichkeiten auf. Die akkumulierte Eintrittswahrscheinlichkeit dieser Szenarien beträgt gem. Tabelle 8 21,45 %. Abbildung 37 zeigt für den Fall der Zielwertüberschreitung exemplarisch den Verlauf den Temperatur- und Stellgrößen am Beispiel des Versuchsszenarios Nr. 426. Wie zu erwarten, fällt die Leistungsaufnahme des PTC-Heizelements ab dem Überschreiten des Energiebudgets bis auf 0 Watt ab. Hierdurch kann der Kabine keine Wärme mehr zugefügt und damit die thermische Last nicht mehr ausgeglichen werden, was wiederum zu einer starken Abkühlung der Kabine führt.

4.2.2.2 Bewertung von Grenzwertverletzungen

Die Zielwerte der Metrik 2-5 werden in allen Versuchsszenarien der Versuchsreihen I und II eingehalten. Unabhängig von den Umgebungsbedingungen wird eine Kabinentemperatur innerhalb des geforderten Temperaturfensters zwischen $15 \text{ }^\circ\text{C}$ und $30 \text{ }^\circ\text{C}$ (Metrik Nr. 2 und Nr. 3) und eine relative Luftfeuchtigkeit unter 80 % (Metrik Nr. 4) eingestellt, sowie ein Taupunktabstand von mindestens $1,5 \text{ K}$ (Metrik Nr. 5) eingehalten.

In der Versuchsreihe III wird die obere Temperaturgrenze in einem Versuchsszenario (Nr. 576) um bis zu maximal 3 K verletzt. Die untere Temperaturgrenze wird in 52 der der 192 Versuchsszenarien der dritten Versuchsreihe verletzt (Metrik Nr. 3). In Anhang A.6 ist die zusammengefasste Auswertung der Metrik Nr. 3 für die drei Versuchsreihen tabellarisch aufgeführt. Die Verletzung des Grenzwertes tritt infolge der Deaktivierung der Heizungsregelung aufgrund des begrenzten Energiebudgets auf.

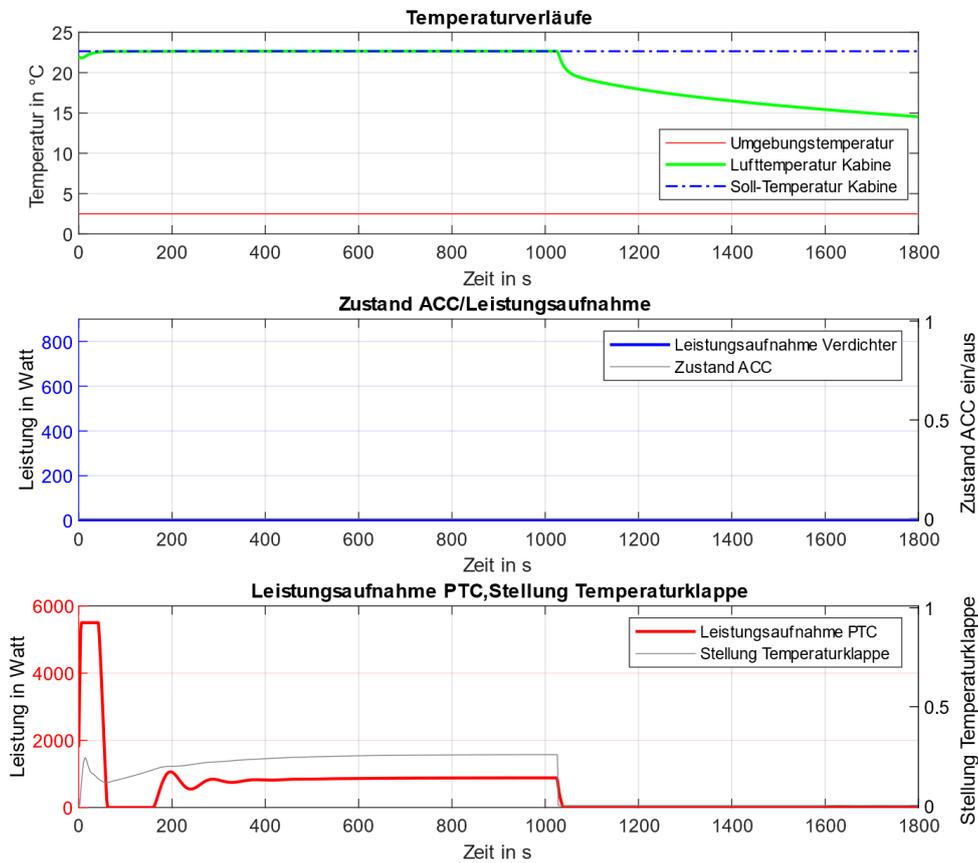


Abbildung 37 Temperatur-, Strahlungs- und Stellgrößenverläufe im Versuchsszenario Nr. 426

4.2.2.3 Bewertung des Energiebedarfs

Die Bewertung des Energiebedarfs der konventionellen Regelung erfolgt durch Auswertung der Metriken gemäß Tabelle 7. Die Metriken entsprechen der durchschnittlichen Leistung der Aggregate bzw. der Gesamtleistung der Klimatisierung über den Verlauf der Versuchsszenarien der einzelnen Testreihen. Die zusammengefasste Auswertung für die drei Versuchsreihen ist in Anhang A.7 bis Anhang A.9 tabellarisch aufgeführt.

	Mittelwert in kW	Maximalwert in kW	Erwartungswert in kW
Versuchsreihe I	0,171	1,123	0,119
Versuchsreihe II	0,171	1,119	0,118
Versuchsreihe III	0,170	1,050	0,119

Tabelle 9 Kennwerte der Verdichterleistung

Die maximale durchschnittliche Verdichterleistung tritt erwartungsgemäß bei maximaler Umgebungstemperatur, maximaler solarer Strahlung und maximaler relativer Luftfeuchte auf und erreicht in der Versuchsreihe I einen Wert von 1,123 kW. Über die die Eintrittswahrscheinlichkeit der Versuchs-

szenarien gemäß Tabelle 8 kann der Erwartungswert der Verdichterleistung für eine Fahrt gemäß Prüfzyklus WLTC berechnet werden. Wie Tabelle 9 zeigt, unterscheiden sich Mittel-, Maximal- und Erwartungswerte der Versuchsreihen nur geringfügig.

Die maximale durchschnittliche Leistung des PTC-Heizelements tritt bei der minimaler Umgebungstemperatur und minimaler solarer Strahlung auf und erreicht in der Versuchsreihe I einen Wert von 5,07 kW. Tabelle 10 zeigt die Mittel-, Maximal- und Erwartungswerte der Versuchsreihen. Der Energiebedarf zum Beheizen des Fahrzeugs bei niedrigen Temperaturen übersteigt den zum Kühlen des Innenraums benötigten Energiebedarf bei heißen Umgebungsbedingungen wesentlich. In 52 der 192 Versuchsszenarien übersteigt der zum Heizen benötigte Energiebedarf das verfügbare Energiebudget, weshalb die eingestellte Leistung begrenzt wird. Dies führt wiederum zu geringeren Leistungskennwerten des PTC-Heizelements in der Versuchsreihe III.

	Mittelwert in kW	Maximalwert in kW	Erwartungswert in kW
Versuchsreihe I	1,41	5,07	0,78
Versuchsreihe II	1,41	5,05	0,78
Versuchsreihe III	0,65	1,13	0,57

Tabelle 10 Kennwerte der PTC-Heizelement-Leistung

Es ergeben sich durchschnittliche Gesamtleistungen zwischen 0,18 kW und 5,07 kW zur Klimatisierung des Fahrzeugs. Das entspricht bei 1800 Sekunden Fahrdauer einem Energiebedarf zwischen 0,09 kWh und 2,535 kWh. Tabelle 11 zeigt die Mittel-, Maximal- und Erwartungswerte der drei Versuchsreihen.

	Mittelwert in kW	Maximalwert in kW	Minimalwert in kW	Erwartungswert in kW
Versuchsreihe I	1,58	5,07	0,18	0,90
Versuchsreihe II	1,58	5,05	0,19	0,90
Versuchsreihe III	0,82	1,13	0,18	0,69

Tabelle 11 Kennwerte der Gesamtleistung

Durch die Klimatisierung des Fahrzeugs ergibt sich, bei einem dem WLTC-Zyklus entsprechenden Fahrprofil, ein Mehrbedarf zwischen 0,39 kWh und 10,90 kWh auf 100 km Fahrstrecke¹⁵. Unter Berücksichtigung der Energiedichte heutiger Lithium-Ionen-Akkumulatoren für BEV von 0,15 kWh/kg ist hierdurch ein Mehrgewicht von bis zu 72 kg pro 100 km Reichweite des Fahrzeugs mitzuführen.

	Mittlere Reichweiten- reduktion	Maximale Reichweiten- reduktion	Minimale Reichweiten- reduktion	Erwartungswert der Reichweiten- reduktion
Versuchsreihe I	6,59%	24,02%	0,86%	4,26%
Versuchsreihe II	6,57%	23,94%	0,90%	4,26%
Versuchsreihe III	3,41%	5,37%	0,86%	3,27%

Tabelle 12 Prozentuale Reichweitenreduktion

Für das Referenzfahrzeug vom Typ e-Golf (Baujahr 2014-2017) ergeben sich bei einer maximalen Nettoenergie des Akkumulators von 21,1 kWh gemäß Zulassungsbescheinigung und einem Energiebedarf

¹⁵ Bei Hochrechnung der 23,25 km langen WLTC-Fahrstrecke auf 100 km.

des Antriebsstrangs von 12,7 kWh/100 km gemäß Herstellerangaben - je nach Umgebungsbedingung - eine Reduktion der Reichweite zwischen 0,86 % und 24,02 % (vgl. Tabelle 12). Das entspricht einer verringerten Reichweite von zwischen 1,5 und 39,8 Kilometern (vgl. Tabelle 13).

	Mittlere Reichweitenreduktion in km	Maximale Reichweitenreduktion in km	Minimale Reichweitenreduktion in km	Erwartungswert der Reichweitenreduktion in km
Versuchsreihe I	-12,5	-39,9	-1,4	-7,1
Versuchsreihe II	-12,4	-39,8	-1,5	-7,1
Versuchsreihe III	-6,4	-8,9	-1,4	-5,4

Tabelle 13 Reichweitenreduktion in Kilometern

Bei einer Jahresfahrleistung von 13,272 km¹⁶ ergibt sich durch Hochrechnung des Erwartungswertes ein jährlicher Energiebedarf zur Klimatisierung eines vergleichbaren batterieelektrischen Fahrzeugs von 513,75 kWh.

4.2.2.4 Zusammenfassende Bewertung

Die konventionelle Regelung zeigt ein zufriedenstellendes Regelverhalten. Sowohl bei statischem als auch dynamischem Verlauf der Umgebungsbedingungen werden die Grenzwerte der Metriken Nr. 2 - Nr. 5 eingehalten. Der Zielwert der Regelgüte gemäß Metrik Nr. 1 wird hierbei nur in Fällen mit sehr hohen Außentemperaturen und sehr hoher solarer Strahlungsleistung geringfügig verletzt. Die Regelgröße der Kabinentemperatur erreicht nach kurzer Einschwingzeit den stationären Zustand. Bei statischen Umgebungsbedingungen ist gegenüber dynamischen Umgebungsbedingungen eine leicht verbesserte Regelgüte zu beobachten.

Der Innenraumklimatisierung ist, insbesondere bei sehr niedrigen Umgebungstemperaturen, durch einen erheblichen Energiebedarf gekennzeichnet. Dieser kann die Reichweite um bis zu 24,02 % reduzieren kann. Der geschätzte jährliche Energiebedarf zur Klimatisierung eines batterieelektrischen Fahrzeugs unter den oben aufgeführten Rahmenbedingungen von 513,75 kWh übersteigt den monatlichen Gesamtstromverbrauch eines 4-Personenhalts 416,67 kWh¹⁷ deutlich. Ein direktes Abschalten der Innenraumklimatisierung aufgrund einer begrenzt verfügbaren Energiemenge führt insbesondere bei niedrigen Umgebungstemperaturen erwartungsgemäß zu erheblichen Verletzungen der oben beschriebenen Anforderungen.

Der höchste Optimierungsbedarf im Sinne einer Reduzierung des Energiebedarfs der Innenraumklimatisierung liegt dementsprechend bei kalten Außentemperaturen. Aufgrund des wesentlich geringeren Energiebedarfs bei moderaten und heißen Umgebungsbedingungen ist hierbei der Optimierungsbedarf geringer. Demgegenüber steht das Optimierungspotential der Regelung durch Veränderung der Heiz- und Kühlfunktion bei den unterschiedlichen Umgebungsbedingungen. Bei kalten klimatischen Umgebungsbedingungen liegt dies vor allem in der Verhinderung vom Überschwingen durch die Regelung. Dieses ist in geringem Maße in der Einschwingphase zu beobachten. In der stationären Phase

¹⁶ Durchschnittliche Jahresfahrleistung je Pkw im Jahr 2018 gemäß Kraftfahrzeugbundesamt (Quelle: <https://www.kba.de>).

¹⁷ Der jährliche Stromverbrauch eines 4-Personen-Haushalts mit Einfamilienhaus betrug in Deutschland im Jahr 2019 5000 kWh (Quelle: <https://de.statista.com>).

ist aufgrund des hohen Wirkungsgrades des PTC-Heizkreislaufs ein geringes Optimierungspotential gegeben.

Bei heißen klimatischen Umgebungsbedingungen liegt das Optimierungspotential des Heizungs- und Klimaanlage-Systems in der Erhöhung der Effizienz des Kältekreislaufs. Diese wird maßgeblich durch die Leistungszahl (COP) des Kältekreislaufs bestimmt. Die Leistungszahl ist abhängig vom Betriebspunkt. Bei kleinen Differenzen zwischen zugeführter und gekühlter Luft können höhere Leistungszahlen als bei großen Differenzen erreicht werden (vgl. hierzu [3] S. 24). Kühlen bei niedrigeren Umgebungstemperaturen führt demnach zu einem höheren COP als bei höheren Umgebungstemperaturen. Durch eine günstige Wahl des Kühlzeitpunktes kann demnach bei dynamischem Verlauf der Umgebungstemperaturen eine höhere Effizienz des Kühlkreislaufs erwartet werden. Weiteres Optimierungspotential bietet die Drehzahl der Verdichterwelle, da diese ebenfalls den COP über ihren Wirkungsgrad des Verdichters am Arbeitspunkt beeinflusst. Die Drehzahl der Verdichterwelle kann durch den gewählten Versuchsaufbau nur über Schaltzeitpunkte und die Schaltdauer der Verdichterregelung beeinflusst werden. Weiteres Optimierungspotential bietet die Abstimmung der Heiz- und Kühlleistung bei moderaten klimatischen Umgebungsbedingungen und bei starker Dynamik der solaren Strahlungsleistung. Das Entgegenwirken von Heiz- und Kühlleistung wird durch die Hysteresen im Mehrpunkt-Klimaregler und in der Kabinentemperaturregelung verringert, aber nicht vollständig verhindert werden. Dies ist darin begründet, dass zum Entwurfszeitpunkt der konventionellen Regelung die Hysteresen so parametrisiert wurden, dass sie für alle möglichen Umgebungsbedingungen ein zufriedenstellendes Umschaltverhalten zwischen Heiz- und Kühlfunktion gewährleisten.

Im Fall einer begrenzt verfügbaren Energiemenge zur Klimatisierung des Innenraums ist eine Optimierung im Sinne der Einhaltung der Grenzwerte bzw. Steigerung der Regelgüte zweckmäßig. Hierbei ist durch eine günstigere Verteilung der verfügbaren Energie insbesondere im Heizfall Optimierungspotential gegeben.

4.3 Zielformulierung

Das übergeordnete Ziel der Arbeit ist die Entwicklung eines Lösungskonzeptes für eine verbesserte temperaturgeführte Regelung einer Einzonen-Klimaanlage. Die Verbesserung liegt hierbei in der Maximierung der Regelgüte bei paralleler Minimierung des Energiebedarfs und der Maximierung der Regelgüte bei begrenztem Energiebudget. Hierzu müssen die benannten Optimierungspotentiale durch eine günstige Wahl der Zeitpunkte des Energieeinsatzes im Heiz- und Kühlkreislauf ausgeschöpft werden. Die Optimierung muss dementsprechend für die konkrete bevorstehende Situation des Systems und der Umgebung erfolgen. Im Gegensatz zu einer reaktiven konventionellen Regelung ist hierzu ein vorrausschauender Ansatz erforderlich. Hierbei müssen zukünftige Verletzungen von Nebenbedingungen und Abweichungen der Regelgrößen durch eine vorrausschauende Arbeitsweise verhindert bzw. minimiert und dabei der Energiebedarf berücksichtigt werden. Da mehrere Funktionen des Heizungs- und Klimaanlage systems betroffen sind, ist eine effiziente Mehrgrößenregelung erforderlich, die sowohl mit zeitverzögerten Signalen umgehen als auch Wissen über zukünftige Zustände des Gesamtsystems berücksichtigen kann. Die konventionelle Regelung muss demnach um einen modellprädiktiven Ansatz ergänzt werden. Für die Umsetzung des modellprädiktiven Ansatzes muss das Zielsystem:

- interne Informationen in Form von Messdaten des Fahrzeugs aufbereiten und verteilen.
- Externe nicht beeinflussbare aber auf das System wirkende Größen hinreichend genau prädictieren.
- Eine optimale Trajektorie der Stellgrößen unter der Berücksichtigung der Regelziele und Nebenbedingungen einstellen können.

Um die optimale Trajektorie der Stellgrößen einzustellen, ist ein Teilsystem erforderlich, dass

- den zukünftigen Zustand des Systems vorhersagen,
- den zukünftigen Zustand des Systems anhand von festgelegten Optimalitätskriterien bewerten,
- sowie den optimalen Verlauf der Stellgrößen unter der Berücksichtigung der auf das System wirkenden Größen sowie der Regelziele und Nebenbedingungen ermitteln kann.

Die wesentliche Voraussetzung für ein befriedigendes Regelungsverhalten eines modellprädiktiven Ansatzes ist es, die Optimierung auf Basis der konkret bevorstehenden Situation des Systems und der Umgebung durchzuführen. Daher ist die hinreichend genaue Vorhersage der betroffenen zukünftigen Regel- und Zustandsgrößen erforderlich. Hierfür ist eine ausreichende Berücksichtigung der Störgrößen, durch deren Vorhersage, wie auch ein Prozessmodell mit hoher Vorhersagequalität erforderlich. Für diese Vorhersage sind sowohl Modelle zur Vorhersage der Störgrößen als auch ein Prozessmodell zur Vorhersage des Zustands des Systems notwendig. Diese Modelle müssen sowohl eine hohe Prognosegüte realisieren, als auch in den Optimierungsprozess integrierbar sein. Bei einem konventionellen theoretischen, hybriden oder experimentellen Modellierungsansatz wird das Modell zur Entwurfszeit abschließend bestimmt. Die Prognosegüte wird dabei anhand vorher definierter Testfälle bestimmt. Werden zur Entwurfszeit des Modells, z.B. durch Parameterabweichungen, Gesetzmäßigkeiten nicht vollständig oder ungenau erfasst, so beeinflusst dies die Prognosegüte zur Einsatzzeit und damit das Regelungsverhalten negativ. Auch ein sich verändertes Systemverhalten z.B. durch veränderte Koeffizienten der Baugruppen kann durch ein statisches Model nicht erfasst werden. Im Rahmen des in dieser Arbeit zu entwickelndem modellprädiktivem Ansatz sind daher Modelle erforderlich, die in der Lage sind, sich adaptiv an verändertes Systemverhalten wie auch sich an veränderte Umgebungsbedingungen anzupassen. Die Modelle müssen daher in der Lage sein, bestehendes Wissen zu

integrieren und neues Wissen im Einsatzfall zu erlernen. Die Modelle müssen fähig sein, die nichtlinearen Dynamiken abzubilden und das gelernte Wissen auf unbekannte Einsatzfälle zu abstrahieren. Hierfür ist eine Lernfähigkeit des Gesamtsystems erforderlich. Das System muss demnach in der Lage sein:

- zum Lernvorgang erforderliche interne und externe Lerndaten zu erheben, vorzuverarbeiten und zu speichern,
- adaptive Modelle zur Störgrößenprognose und Prozessvorhersage zu trainieren,
- und innerhalb des Systems zu aktualisieren.

Zu den in 4.2.1 aufgeführten Anforderungen an das konventionelle System müssen weitere Anforderungen hinsichtlich des Energiebedarfs für das zu entwerfende Gesamtsystem festgelegt werden. Hierzu müssen die identifizierten Verbesserungspotentiale quantifiziert und in Relation zum konventionellen System gesetzt werden.

5 Systemsynthese- und Analyse

Ausgehend von der Situationsanalyse und Zielformulierung erfolgt in der Systemsynthese gemäß VDI-Richtlinie 2206 die Erarbeitung von alternativen Lösungsvarianten. In dieser Arbeit wird eine Lösungsvariante auf Basis des im Kapitel 2.2 vorgestellten grundlegenden Konzeptes der modellprädiktiven Regelung erarbeitet. Die Einsatzbedingungen entsprechen den in der Situationsanalyse dargestellten Einsatzbedingungen der konventionellen Regelung. Im folgenden Kapitel 5.1 wird aus der vorangegangenen Zielformulierung eine Funktionsstruktur abgeleitet. Ausgehend von der Funktionsstruktur wird ein Grobkonzept des Lösungsansatzes entworfen. Hierauf aufbauend werden in den folgenden Unterkapiteln Lösungsvarianten für Teillösungen des Gesamtansatzes weiter konkretisiert und im abschließenden Unterkapitel 5.6 zu einer Steuerung zusammengeführt. Hierbei findet ein „permanentes Wechselspiel von Synthese- und Analyseschritten“ statt (vgl. [92] S.27). Im anschließenden Kapitel 6 erfolgt die zur Entscheidungsfindung führende Analyse und Bewertung der erarbeiteten Lösungsvariante. Hierauf aufbauend wird das weitere Vorgehen zur Weiterentwicklung der erarbeitenden Lösungsvariante diskutiert.

Entwicklungsgegenstand des ersten Mikrozykluses und damit die zu entwerfende Gesamtfunktion ist zunächst die Steuerung des Heizungs- und Klimaanlageansystem durch Einstellung der Position der Temperaturklappe und Schalten des Zustandes der Kühlkreislaufs. Basierend auf dem so entworfenen Lösungsansatzes kann durch erneutes Durchlaufen des Mikrozykluses die Steuerung mit einer Rückkopplung komponiert und so ein Lösungsansatz für die Regelung gewonnen werden.

5.1 Konzept der Lernenden Modellprädiktiven Regelung (Grobkonzept)

Zum Entwurf des Ansatzes wird die Gesamtfunktion in Teilfunktionen untergliedert. Diese werden aus der vorangegangenen Zielformulierung abgeleitet. Als Teilfunktionen des Gesamtlösungsansatzes werden die in Tabelle 14 dargestellten Funktionen festgelegt:

Funktion	Beschreibung
Lokale Datenverwaltung	Fahrzeugdaten abrufen
	Fahrzeugdaten aufbereiten
	Wetterdaten abrufen
	Wetterdaten aufbereiten
	Trainingsdaten speichern
	Prognoseinputdaten verteilen
Externe Datenverwaltung	Trainings-, Prognose- und Modelldatendaten verwalten
Modelltraining	Störgrößenmodelle trainieren
	Prozessmodell Kabinenklima trainieren
Störgrößenprognose	Störgrößen vorhersagen
Optimierung	Systemzustand vorhersagen
	Systemzustand bewerten
	Stellgrößen ermitteln

Tabelle 14 Teilfunktionen des Gesamtlösungsansatzes

Die Funktionsstruktur und damit die fachliche Architektur des Gesamtsystems ergibt sich aus der Kommunikation der einzelnen Teilfunktionen. Abbildung 38 zeigt die abgeleitete Funktionsstruktur durch die in einzelnen Komponenten zu realisierenden Teilfunktionen. Das Zusammenspiel der Kompo-

nennten wird über das Verhalten der Funktionsstruktur beschrieben. Dies entspricht der Wirkstruktur der VDI-Richtlinie 2206. Hierin wird das „Lösungsprinzip zum Erfüllen der Gesamtaufgabe erkennbar“ [92].

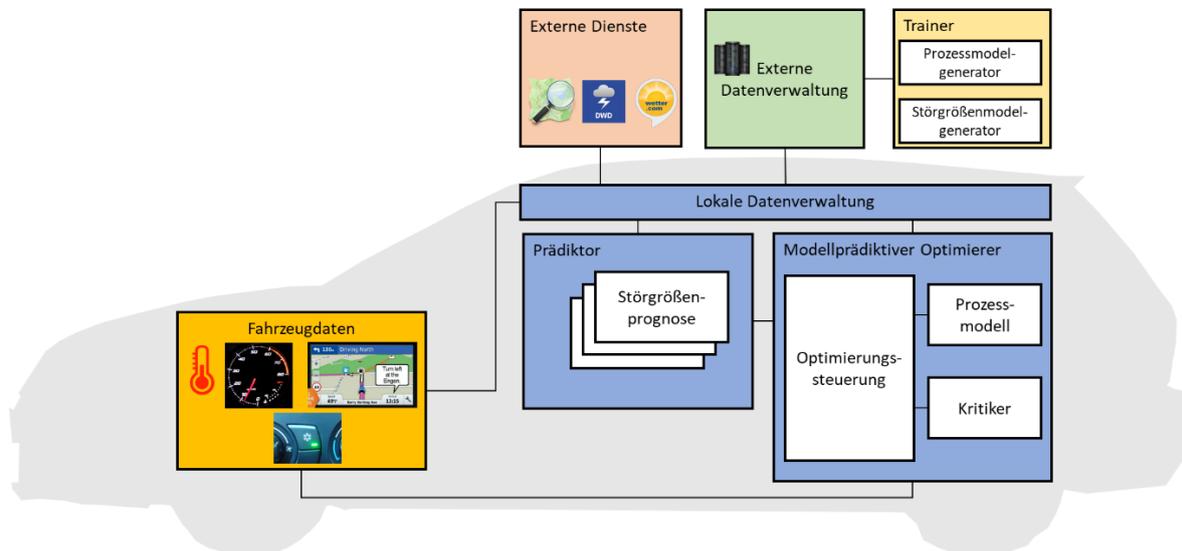


Abbildung 38 Fachliche Architektur des Gesamtsystems

Die lokale Datenverwaltung empfängt Messdaten des Fahrzeugs. Dies sind neben Geschwindigkeit, Richtung und geographischer Position des Fahrzeugs, Routendaten des Navigationssystems wie Zielort und Streckenführung. Zum anderen empfängt die lokale Datenverwaltung klimarelevante Fahrzeugdaten. Dies sind Daten der Sensorik (Temperatur-, Feuchtigkeits-, Sonnenlichtdurchdringungssensoren), Aktorik (Klappenstellungen) sowie Leistungsdaten (PTC- und Verdichterleistung). Die Fahrzeugdaten werden für spätere Lernprozesse (Trainingsdaten) sowie für die folgenden Prognosen (Prognoseinput) aufbereitet. Zur Durchführung der Störgrößenprognose werden des Weiteren Wetterdaten über externe Wetterdienste abgerufen und ebenso als Prognoseinput aufbereitet. Sowohl dem Prädiktor als auch dem Optimierer werden aufbereitete Prognoseinput-Daten zur Verfügung gestellt.

Der Prädiktor empfängt die von der lokalen Datenverwaltung aufbereiteten und bereitgestellten Prognoseinput-Daten und prädiziert externe nicht beeinflussbare aber auf das System wirkende Störgrößen. Die Störgrößenprognose wird zur Weiterverarbeitung im Optimierer aufbereitet und diesem zur Verfügung gestellt. Die Prognosen der Störgrößen erfolgen über verschiedene Störgrößenprognose-Modelle, welche über eine Schnittstelle zur lokalen Datenverwaltung aktualisiert werden.

Der Modellprädiktive Optimierer ermittelt eine optimale Trajektorie der Stellgrößen Temperaturklappe und ACC-Zustand unter der Berücksichtigung der Regelziele und Nebenbedingungen. Hierzu wird ein Optimierungsverfahren verwendet, das unter Verwendung eines Modells den zukünftigen Zustand des Systems vorhergesagt, anhand von festgelegten Optimalitätskriterien bewertet und einen optimalen Verlauf der Stellgrößen ermittelt. Zur Prognose des zukünftigen Systemzustands empfängt der Modellprädiktive Optimierer die vom Prädiktor bereitgestellte Störgrößenprognose sowie den von der lokalen Datenverwaltung in Form des Prognoseinputs aufbereiteten Zustand des Fahrzeugs. Die Prognose des zukünftigen Zustands des Systems erfolgt über ein Prozessmodell auf Basis maschinellen Lernens, welches über eine Schnittstelle zur lokalen Datenverwaltung aktualisiert wird. Die Optimierung erfolgt über eine Anpassung der Stellgrößen durch die Optimierungssteuerung in Abhängigkeit der Bewertung des Zustands durch den Kritiker. Die zur Optimierung erforderlichen Regelziele und

Nebenbedingungen werden ebenfalls über eine Kommunikation zur lokalen Datenverwaltung empfangen. Ergebnis der Optimierung sind die zeitlichen Stellfolgen der Stellgrößen Temperaturklappe und Zustand der Kühlkreislaufs. Die ermittelten optimalen Stellfolgen werden zur weiteren Regelung über Schnittstellen dem Klimasteuergerät des Fahrzeugs bereitgestellt.

Der Trainer führt die Lernverfahren zum Training des Prozessmodells und der Störgrößenmodelle durch. Hierzu ruft er die erforderlichen Trainingsdaten aus der externen Datenverwaltung ab. Nach Durchführung des Trainings- und Evaluierungsprozesses werden die trainierten Modelle mit ihren Metadaten in einer Datenbank der externen Datenverwaltung abgelegt. Die Beschreibung der im Trainer zur Modellbildung der Störgrößenmodelle und des Prozessmodells eingesetzten Lernverfahren erfolgt im folgenden Unterkapitel.

5.2 Modellbildung durch Verfahren des maschinellen Lernens

Da sowohl Modelle zur Störgrößenprognose als auch ein Modell zur Prozessprognose erforderlich sind, muss die Teilfunktion Trainer in weitere Teilfunktionen untergliedert werden. Das notwendige Vorgehen für die Entwicklung der einzelnen Teilfunktionen zur Modellbildung durch Verfahren des maschinellen Lernens wird im Folgenden beschrieben.

Die Güte einer modellprädiktiven Regelung hängt im Wesentlichen von der Güte der Vorhersage der Regel- und Zustandsgrößen ab. Diese unterliegt zum einen der Abbildungsgenauigkeit des Prozessmodells und zum anderen der Güte der Vorhersage der nichtbeeinflussbaren Eingänge des Prozessmodells. Um eine hohe Güte der Vorhersagen der Regel- und Zustandsgrößen auch zur Einsatzzeit der Regelung zu gewährleisten, werden Modelle auf der Basis von Verfahren des maschinellen Lernens im Prädiktor und im Modellprädiktiven Optimierer eingesetzt. Die Modellbildung wird innerhalb der Teilfunktion Trainer umgesetzt. In den folgenden beiden Unterkapiteln erfolgt die Beschreibung der angewandten Lernverfahren zum Training der Modelle.

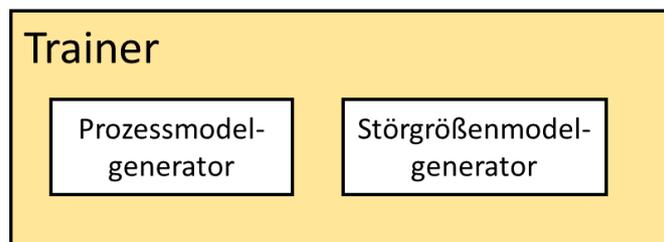


Abbildung 39 Untergliederung der Teilfunktion Trainer

Das grundsätzliche Vorgehen zur Entwicklung der Modelle auf der Basis maschinellen Lernens orientiert sich in dieser Arbeit am CRISP-DM-Vorgehensmodell (Cross-Industry Standard Process for Data Mining). Das Vorgehensmodell entstammt eigentlich aus dem Gebiet des KDD (Knowledge Discovery in Databases), wofür oft synonym der Begriff Data-Mining verwendet wird. Es eignet sich aber aufgrund der engen Verwandtschaft mit dem Gebiet des maschinellen Lernens mit leichter Abwandlung zur Erstellung von Prozessmodellen, da die benötigten prinzipiellen Entwicklungsschritte hierin enthalten sind. Eine detaillierte Beschreibung des Vorgehensmodells im Vergleich zu alternativen Modellen findet sich in [124]. Das Vorgehensmodell wurde für branchenübergreifende KDDM-Projekte (Knowledge Discovery and Data Mining Projects) entwickelt und beschreibt den Wissensentdeckungsprozess von der Datenerhebung, -auswahl, -bereinigung, -reduktion und -transformation über die Modellbildung und Validierung bis zum Einsatz der entwickelten Modelle. Es unterscheidet 6 Phasen die im Wechselspiel und nicht zwingend sequentiell hintereinander durchlaufen werden. Das CRISP-DM-

Vorgehensmodell wird daher auch als Data-Science-Lifecycle bezeichnet. Abbildung 40 zeigt das in Anlehnung an das CRISP-DM-Vorgehensmodell gewählte grobe Vorgehen zur Modellbildung.

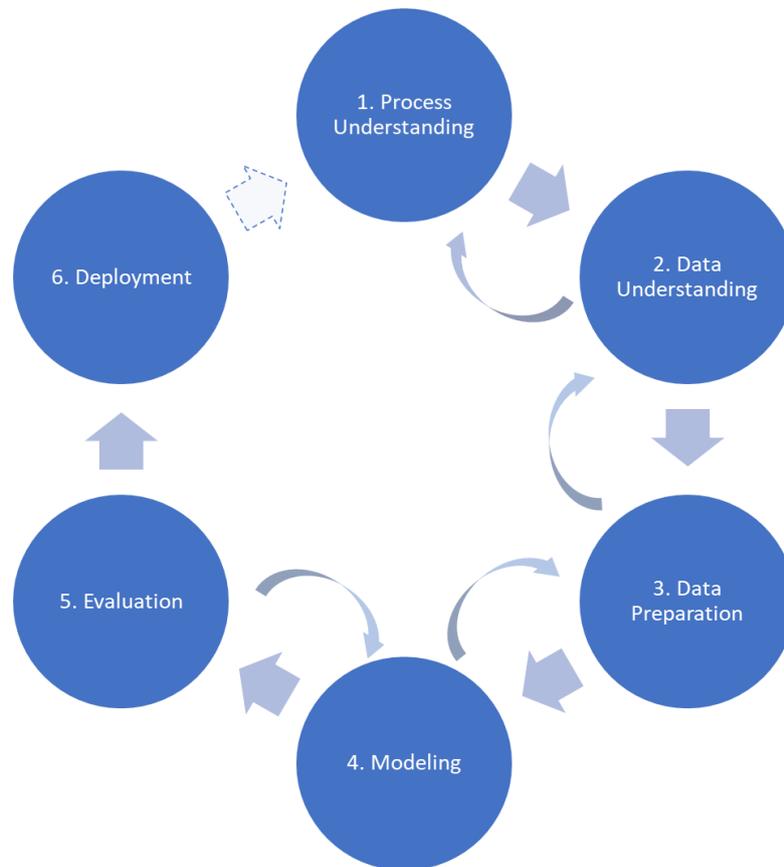


Abbildung 40 Vorgehen zur Modellentwicklung in Anlehnung an das CRISP-DM-Vorgehensmodell

In der ersten Phase, dem Process Understanding¹⁸, wird Hintergrundwissen der betroffenen Domäne und damit des betroffenen technischen Prozesses gesammelt, Ziele und Anforderung der Wissensfindung formuliert und die grobe Vorgehensweise festgelegt. In der folgenden Phase, dem Data Understanding, erfolgt die Entwicklung einer Methodik zur Datenerfassung aus internen und externen Quellen. Dies beinhaltet Konzepte für Datenextraktion und Datenübertragung der relevanten Prädiktoren für das Prognoseverfahren. Hierbei sollen frühzeitig Probleme der Datenqualität erkannt werden. Des Weiteren wird die Datengrundlage analysiert, Kausalitäten untersucht, eine Vorauswahl relevanter Prädiktoren sowie die Zielgrößen der Prognose (Target Data) festgelegt. In der dritten Phase der Data Preparation erfolgt die Auswahl eines geeigneten Modellierungsverfahrens und die Erstellung des Trainingsdatensatzes. Hierbei werden zunächst die Daten „gesäubert“ (Data Cleaning). Der Gesamtdatensatz wird dabei unter anderem auf Messfehler, Ausreißer und unplausible Daten untersucht und die betroffenen Werte mit geeigneten Verfahren wie z.B. Interpolationsverfahren durch plausible Werte ersetzt. Ebenfalls kommen in dieser Phase Filterverfahren zum Entfernen von Messrauschen zum Einsatz. Anschließend erfolgt eine weitere Vorverarbeitung und ggf. eine Dimensionsreduktion. Hierbei werden unter anderem Zeitraster und Auflösung der Daten an die Fragestellung angepasst. Abschließend erfolgt in dieser Phase die Transformation der Daten in eine zur Einspeisung in das Modell geeignete Form. In der vierten Phase erfolgt die Modellbildung durch Festlegung der Modellstruktur und der Hyperparameter sowie das Training des Modells. Anschließend wird in einer fünften Phase das

¹⁸ Im CRISP-DM-Vorgehensmodell wird diese Phase als Business Understanding bezeichnet.

Modell anhand von Testdaten evaluiert. Hierbei ist es in der Regel erforderlich, auf vorherige Phasen zurückzuspringen und diese erneut zu durchlaufen bis ein zufriedenstellendes Evaluationsergebnis erreicht wird. Ist die Evaluation erfolgreich, kann das Modell in der abschließenden sechsten Phase, dem Deployment, zum Einsatz innerhalb des Gesamtsystems bereitgestellt werden. Das Vorgehen zur Modellentwicklung im Rahmen dieser Arbeit stellt einen Syntheseschritt im übergeordneten Mikrozyklus dar. Auf diesen Syntheseschritt folgt ein weiterer Analyseschritt. Liefert dieser Analyseschritt ein unbefriedigendes Ergebnis, so werden die Zyklen der Modellentwicklung der jeweiligen Modelle erneut durchlaufen.

5.2.1 Modellbildung des Prozessmodells

5.2.1.1 *Phase 1 - Process Understanding*

Ziel der Prozess-Modellbildung ist die Vorhersage der betroffenen zukünftigen Regel- und Zustandsgrößen. Bezugsgröße der Vorhersage ist damit die Zeit, ausgehend vom aktuellen Zeitpunkt bis zum Ende des zeitlichen Prognosefensters. Wie in Kapitel 2.1.4 aufgeführt, bieten künstliche neuronale Netze eine Alternative zur konventionellen physikalischen Modellbildung technischer Prozesse. Im Besonderen haben rekurrente neuronale Netze die Fähigkeit, nichtlineare Dynamiken zu lernen und damit abzubilden. Durch die Möglichkeit ein vortrainiertes Netz mit neuen Daten nachzulernen, bieten sie des Weiteren eine Anpassungsfähigkeit an sich veränderndes oder noch nicht bekanntes Systemverhalten. Die in der Einleitung erwähnten Arbeiten zur Modellierung des Kabinenklimas mit künstlich neuronalen Netzen [44] - [47] zeigen vielversprechende Ergebnisse, allerdings nur für kurze Prognosehorizonte. Hierbei wurden Varianten des in Kapitel 2.1.4.3 beschriebenen NARX-Verfahrens eingesetzt. Für längere Prognosehorizonte und einen großen Betriebsbereich sind die bekannten Arbeiten jedoch nur begrenzt zur Verwendung innerhalb eines MPC geeignet. Ein Grund hierfür ist die Fehlerakkumulation aufgrund mehrerer aufeinanderfolgenden Ein-Schritt-Vorhersagen. Die Ausgabe jedes Vorhersageschritts entlang des Vorhersagezeitfensters wird als Eingabe für den folgenden Vorhersageschritt verwendet. Infolgedessen verstärkt sich der Fehler mit jedem Zeitschritt, was zu hohen Ungenauigkeiten für längere Prognosefenster führt. Eine weitere Problematik des NARX-Verfahrens ist die Laufzeit. Da zur Prognose innerhalb eines Zeitschrittes immer das Ergebnis des letzten Zeitschrittes als Input benötigt wird, muss das Verfahren zur Berechnung einer Trajektorie sequenziell ausgeführt werden. Eine Alternative hierzu bietet die Modellbildung durch LSTM-Netze. Basierend auf dieser Netzwerkstruktur wird im Folgenden ein tiefes neuronales Netzwerk zur Modellbildung des Heizungs-, Lüftungs- und Klimaanlage systems und der Fahrzeugkabine entwickelt. Da die Analyse der betroffenen Domäne der Fahrzeugklimatisierung in Kapitel 3 sowie die Situationsanalyse und Zielformulierung in Kapitel 4 bereits durchgeführt sind, ist die erste Phase der Modellentwicklung des Prozessmodells abgeschlossen.

5.2.1.2 *Phase 2 - Data Understanding*

Das weitere Vorgehen unterliegt zwei wesentlichen Herausforderungen. Einerseits besteht ein wesentliches Problem in der Sicherstellung der Qualität der Lerndaten als wesentliche Grundlage aller Lernmethoden. Die Werte physikalischer Modelleingangsgrößen, die durch Messungen physikalischer Prozesse erhalten werden, unterliegen Abweichungen aufgrund von Messunsicherheiten und Messabweichungen. Die Qualität von Lernsystemen ist stark durch die Qualität der Lerndaten begrenzt. Andererseits muss nach der Auswahl des Modellierungsverfahrens eine zur Abbildung der Systemdynamik geeignete Struktur des Netzes gefunden werden. Die Struktur eines künstlich neuronalen Netzes wird durch die Anzahl der Schichten, Anzahl der Neuronen innerhalb der Schichten und im Falle von rekurrenten neuronalen Netzen durch den Aufbau der Zellen bestimmt. Diese Struktur bestimmt die

Komplexität des Modells. Um Über- und Unteranpassung zu vermeiden, sollte die Komplexität des Modells der Komplexität des abzubildenden Systems entsprechen. Die tatsächliche Struktur des abzubildenden Systems ist allerdings unbekannt, weshalb eine geeignete Komplexität und damit die Struktur des Modells nur indirekt bestimmt werden kann. Eine Möglichkeit der Modellstrukturbestimmung ist der empirische Modellvergleich mit einer Schätzung des Generalisierungsfehlers. Zur Schätzung des Generalisierungsfehlers sind sowohl Trainingsdaten für den Lernprozess unterschiedlicher Modelle mit verschiedener Modellstruktur als auch Testdaten erforderlich. Da in frühen Entwicklungsphasen des Gesamtsystems in der Regel keine Fahrzeugprototypen zur Verfügung stehen (vgl. hierzu Kapitel 3.1.), können die erforderlichen Trainings- und Testdaten nicht durch Fahrzeugmessungen erhoben werden. Die Datengrundlage ist aber wesentliche Voraussetzung zur Durchführung der Phase 2. Allerdings können aus den Ergebnissen der in Kapitel 4.1 durchgeführten konventionellen Modellbildung, die für die Phase 2 benötigten wesentlichen Erkenntnisse abgeleitet werden. So können die Eingänge des konventionellen Modells als Features des Lernenden Modells und die Ausgänge als Targets übernommen werden, da die Kausalität des Gesamtprozesses bereits analysiert worden ist. Ebenso können Zeitraster und Auflösung der Ein- und Ausgangsgrößen direkt übernommen werden.

5.2.1.3 Phase 3 - Data Preparation

Da beim erstmaligen Durchlauf der dritten Phase die erforderlichen Trainings- und Testdaten nicht zur Verfügung stehen, müssen diese initial gewonnen werden. Dies erfolgt hierbei zunächst anhand des konventionellen Modells. In späteren Entwicklungsphasen kann die Gewinnung der initialen Lerndaten im Klimawindkanal durchgeführt werden, da so alle relevanten Umgebungsbedingungen reproduziert werden können. Zur Gewinnung der Trainings- und Testdaten wird ein Ansatz in Anlehnung an die konventionelle experimentelle Modellbildung durch Systemidentifikation gewählt.

Eingangsgröße	Bezeichner	Einheit	Kategorie	Min	Max	Δ_{\max}
Umgebungstemperatur	T_u	K	kontinuierlich	228,15 K	318,15 K	0,5
rel. Außenluftfeuchte	ϕ_u	%	kontinuierlich	0 %	100 %	2
Strahlungsleistung direkt	$P_{\text{sol,dir}}$	W/m ²	kontinuierlich	0 W/m ²	900 W/m ²	2
Strahlungsleistung diffus	$P_{\text{sol,diff}}$	W/m ²	kontinuierlich	0 W/m ²	300 W/m ²	2
Solltemperatur der Luft nach Verdampfer	$T_{\text{ev,soll}}$	°C	kontinuierlich	2 °C	18 °C	0,2
Nachlauftemperatur PTC	T_{PTC}	°C	kontinuierlich	20 °C	90 °C	0,2
Fahrzeuggeschwindigkeit	v	km/h	kontinuierlich	0 km/h	160 km/h	0,5
Umluftklappenstellung	u	-	diskret	0	1	0,1
Zustand ACC	ACC	-	diskret	0	1	1
Temperaturklappenstellung	tk	-	diskret	0	1	0,1
Gebälsestufe	G	-	diskret	1	7	1

Tabelle 15 Spezifikation der Testsignale

Wie bei der konventionellen experimentellen Modellbildung wird dabei das System mit Testsignalen stimuliert und die Systemantwort gemessen. Aus diesen Daten werden dann die Eingänge und Zielausgänge für das Lernverfahren durch Transformation in die einspeisbare Form generiert. Zur Generierung der Testsignale wurden zunächst die Randbedingungen spezifiziert. Neben einer Dauer von 1800 Sekunden und einem Zeitraster von 2 Sekunden, werden Minimal- und Maximalwerte sowie ein Δ_{\max} zur Begrenzung des maximalen Anstiegs pro Zeitschritt festgelegt. Tabelle 15 zeigt die spezifizierten Randbedingungen zur Generierung der Testsignale. Zur Generierung der Testsignale werden 4 verschiedene Signalarten verwendet. Dies sind statischer, periodischer, aperiodischer Signalverlauf und ein Signalverlauf als Sprungfunktion. Der statische Signalverlauf wird durch jeweils normalverteilte Pseudozufallszahlen innerhalb des Wertebereichs der Eingangsgröße generiert. Zur Abbildung der Sprungfunktionen werden Startwert, Sprunghöhe und Zeitpunkt des Sprungs durch normalverteilte Pseudozufallszahlen innerhalb der Spezifikation gemäß Tabelle 15 festgelegt und hieraus das Signal generiert. Für den jeweiligen Signalverlauf der periodischen und aperiodischen Signalverläufe der einzelnen Eingangsgrößen muss berücksichtigt werden, dass diese sich durch den möglichen Zeitpunkt der Wertänderung unterscheiden. Während der Zeitpunkt der Wertänderung der physikalischen Messgrößen kontinuierlich ist, kann der Zeitpunkt der Werteänderung der Stellgrößen z.T. diskret bzw. äquidistant sein. Dies gilt zum Beispiel für die Gebläsestufe (1 bis 7) und den Zustand des ACCs (ein oder aus). Der kontinuierliche Signalverlauf wird daher durch ein Sinus- bzw. Rechtecksignal konstruiert. Hierbei werden Mittelwert, Amplitude und Frequenz der Signale durch normalverteilte Pseudozufallszahlen erzeugt. Zur Erzeugung des aperiodischen Signalverlaufs wird ein Random-Walk-Verfahren eingesetzt. Abbildung 41 zeigt beispielhaft generierte Signale für die Eingangsgrößen Umgebungstemperatur und Zustand ACC mit statischem, periodischem, aperiodischem Signalverlauf und Signalverlauf als Sprungfunktion.

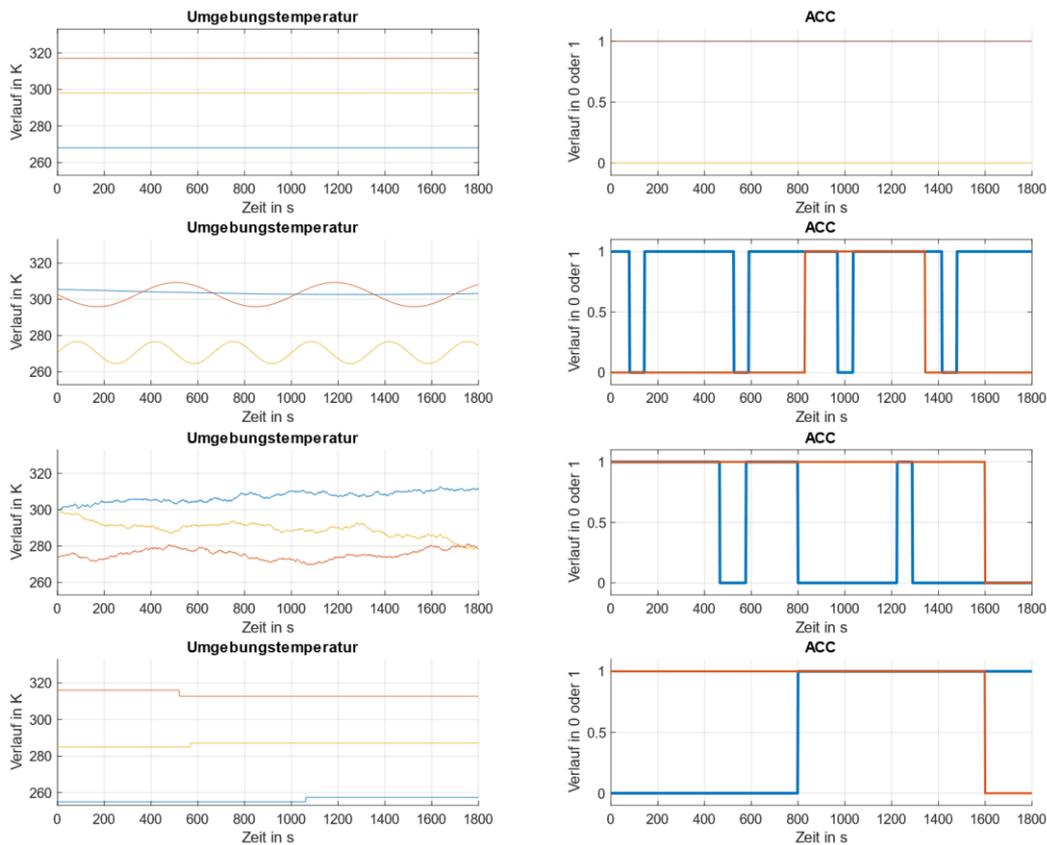


Abbildung 41 Generierte Testsignale für Umgebungstemperatur und Zustand ACC

Um verschiedene Kombinationen der Eingangssignalarten für die Eingangsgrößen zu realisieren, wurden die Eingangssignale in 7 verschiedenen Gruppen erzeugt:

1. Konstante Eingangssignale für alle Eingangsgrößen
2. Periodische Eingangssignale für alle Eingangsgrößen
3. Aperiodische Eingangssignale für alle Eingangsgrößen
4. Sprungfunktionen als Eingangssignale für alle Eingangsgrößen
5. Eine zufällige Eingangsgröße mit periodischen Eingangssignal, die restlichen Eingangsgrößen konstant.
6. Eine zufällige Eingangsgrößen mit aperiodisch Eingangssignal, die restlichen Eingangsgrößen konstant.
7. Eine zufällige Eingangsgrößen mit Sprungfunktion als Eingangssignal, die restlichen Eingangsgrößen konstant.

Für jede Gruppe wurde die Signalgenerierung 200 Mal wiederholt, so dass insgesamt Testsignale für 1400 Simulationen erzeugt wurden. Zur Gewinnung der initialen Trainings- und Testdaten wurde die in Kapitel 4.1 beschriebene FMU des Modelica-Gesamtmodells des Heizungs-, Lüftungs- und Klimaanlage-Systems und der Fahrzeugkabine in ein Matlab-Simulink-Modell integriert. Das Modell wurde entsprechend dem in Kapitel 4.2.1 beschriebenen Vorgehen initialisiert und mit diesem die Simulationen für die generierten Testsignale durchgeführt. Hierbei wurden insgesamt 700 Stunden Fahrzeit simuliert. Die Berechnungsdauer zur Durchführung der 1400 Simulationen betrug 99,3 Stunden. Die so erzeugten Trainings- und Testdaten wurden durch den letzten Arbeitsschritt der Data Preparation, der Datentransformation in einer zur Modelleinspeisung geeignete Form, vorbereitet. Hierbei wurden die zeitlich aufeinanderfolgenden Ein- und Ausgänge der Simulation jeweils entlang der Zeit aufgerollt und so zu Sequenzen zusammengefasst. Da jede Sequenz eine Zeitspanne über 1800 Sekunden mit einem Abtastintervall von zwei Sekunden umfasst, besteht jede Sequenz aus 900 diskreten Werten pro Signal. Die so entstandenen Matrizen mit den Dimensionen Eingangs- bzw. Ausgangsgrößen und Zeitschritte wurden in einer Matlab-Zell-Struktur (cell array) mit den Dimensionen 1400x1 aggregiert und somit in das für LSTM-Netze erforderlich 3D-Dataframe-Format transformiert. Hieraufhin wurde der Gesamtdatensatz pseudozufallszahlbasiert in einem Verhältnis 2:1 in Trainings- und Testdaten aufteilt. Abschließend wurden, nach Ermittlung der Mittelwerte und Standardabweichungen des Trainingsdatensatzes, Trainings- und Testdatensatz standardisiert. Wird die dritte Phase nach dem initialen Lernvorgang erneut durchlaufen, so ändert sich das Vorgehen innerhalb dieser Phase erheblich, da die Trainings- und Testdaten aus Messwerten des Gesamtsystems gewonnen werden. Die Verarbeitungsschritte bis einschließlich der Datentransformation werden nicht innerhalb der Teilfunktion Trainer, sondern innerhalb der Teilfunktion lokale Datenverwaltung durchgeführt. Diese einzelnen Verarbeitungsschritte werden im Kapitel 5.3 dargestellt.

5.2.1.4 Phase 4 - Modeling

In der anschließenden vierten Phase erfolgt die Modellbildung. Wie einleitend begründet, wird zur Modellierung der Zeitreihenprognose ein auf LSTM-Zellen basierendes tiefes rekurrentes neuronales Netz verwendet. Als Modellierungswerkzeug wurde die Matlab Deep Learning Toolbox™ verwendet. Die Modellauswahl zur Festlegung der Modellstruktur erfolgt über einen empirische Modellvergleich mit Schätzung des Generalisierungsfehlers. Der Generalisierungsfehler wurde anhand des Testdatensatzes geschätzt. Hierfür wurde der durchschnittliche RMSE zwischen den jeweiligen Ausgängen der Testdatensätze und denen der Prognose ausgewertet. Zur Durchführung des Modellvergleichs wurden zunächst die Hyperparameter gem. Tabelle 16 eingestellt.

Trainingsoption/Hyperparameter	Bezeichner	Wert/Option
Epochenanzahl	MaxEpochs	2500
Optimierungsverfahren	solverName	adam
Mini-Batch-Größe	MiniBatchSize	450
Initiale Lernrate μ	InitialLearnRate	0,01
L2-Regularisierungsfaktor	L2Regularization	0,0001
Ausführungsumgebung	ExecutionEnvironment	GPU
Zerfallsrate β	GradientDecayFactor	0,9

Tabelle 16 Gewählte Hyperparameter

Anschließend wurden 124 Modelle mit einer Tiefe von 1-4 verdeckten LSTM-Schichten und jeweils unterschiedlicher Anzahl an LSTM-Zellen pro Schicht (0, 40, 80, 100, 120, 200) generiert. Vor die verdeckten LSTM-Schichten wurde jeweils eine Schicht zur Sequenzeingabe (Sequence Input Layer), hinter die verdeckten Schichten wurde jeweils eine vollständig verbundene Schicht (Fully Connected Layer) zur Berechnung der Netzausgabe, sowie eine Regressionsschicht (Regression Layer) zur Berechnung der Lossfunktion eingefügt. Für die so erzeugten Modelle wurde jeweils der Lernvorgang durchgeführt und der geschätzte Generalisierungsfehler ermittelt. Der Versuch zeigte eine Verringerung des Generalisierungsfehlers mit zunehmender Netztiefe und steigender Anzahl der LSTM-Zellen. Da allerdings ab einer Netztiefe von 2 verdeckten LSTM-Schichten mit jeweils 200 bzw. 100 LSTM-Zellen keine Verringerung des Generalisierungsfehlers mehr erzielt wurde, wurde diese Modellstruktur für das weitere Vorgehen festgelegt. Das resultierende Modell wurde mit einer deutlich erhöhten Anzahl von 100000 Lernepochen nachtrainiert. Hierbei wurde die Lernrate durch ein Lernraten-Scheduling-Verfahren während des Lernvorgangs verändert. Die Lernrate wurde dabei alle 5000 Epochen um den Faktor 0,8 reduziert.

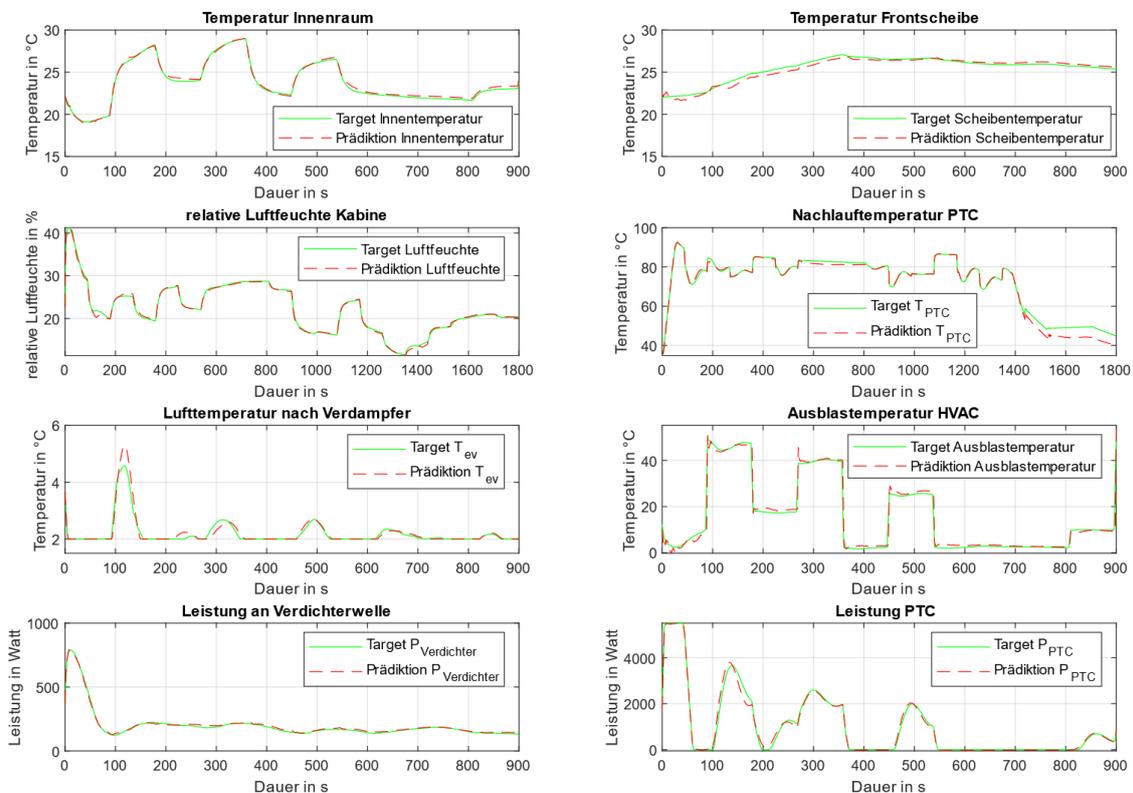


Abbildung 42 Verlauf der prädizierten Ausgangsgrößen

5.2.1.5 Phase 5 - Evaluation

Nach Abschluss des Trainingsvorgangs kann die fünfte Phase der Modellentwicklung, die Evaluation durchlaufen werden. Hierbei wurde das trainierte Modell anhand der vorher ungesehenen Testdaten evaluiert. Abbildung 42 zeigt beispielhaft den Verlauf von Zielgrößen und der prädizierten Größen anhand der Ergebnisse einer Testdatenreihe des Testdatensatzes.

Zur Bewertung der Abbildungsgüte wurde für jede Testdatenreihe des Testdatensatzes das quadratische Mittel (RMSE), der mittlere absolute Fehler (MAE), die Verzerrung (BIAS) sowie Minimum, Maximum und Median des Fehlers ermittelt. Diese Metriken wurden durch Bildung des Mittelwertes über alle Testdatenreihen aggregiert. Tabelle 17 zeigt die Zusammenfassung der Bewertung des initialen Lernvorgangs. Insgesamt wiesen alle prädizierten Größen eine geringe Abweichung zu den Zielgrößen auf. Die höchsten Prädiktionsfehler traten bei der Prädiktion der Leistung des PTC-Elements auf. Dieser resultiert aus dem hohen Wertebereich der Leistung und hohen Sprüngen des Leistungsverlaufs. Durch einen leichten zeitlichen Versatz zwischen prädizierten und prognostizierten Leistungen entstehen vereinzelt höhere Prädiktionsfehler. Die mittlere Verzerrung der aufgenommenen PTC-Leistung von ca. einem Watt ist im Vergleich zu den Arbeitspunkten im Kilowattbereich extrem niedrig und daher akzeptabel. Die Nachlauftemperatur im Heizkreislauf sowie die Ausblastemperatur weisen ebenfalls vereinzelt höhere Prädiktionsfehler auf. Die Prädiktion dieser Größen weist aber ebenfalls eine sehr geringe Verzerrung auf.

Größe	Einheit	RMSE	MAE	BIAS	Fehler Max.	Fehler Min.	Fehler Median
Temperatur Innenraum	°C	0,111621	0,084623	0,004034	0,439566	0,000247	0,068188
Temperatur Frontscheibe	°C	0,096783	0,076942	-0,001284	0,380351	0,000385	0,064728
rel. Luftfeuchte Kabine	%	0,191674	0,148513	-0,016758	0,736630	0,000301	0,121140
Nachlauftemperatur PTC	°C	0,403023	0,210448	0,038548	3,303116	0,000466	0,117268
Lufttemperatur nach Verdampfer	°C	0,032528	0,019932	0,000131	0,194791	0,000020	0,012276
Ausblastemperatur HVAC	°C	1,469203	0,451814	0,010267	18,345371	0,000827	0,187654
Leistung an Verdichterwelle	Watt	3,726651	2,167511	-0,088400	26,713577	0,002653	1,212334
Leistung PTC	Watt	36,056091	15,417624	1,101998	296,978088	0,020119	6,920806

Tabelle 17 Zusammenfassung der Metriken des initialen Lernvorgangs

Zur Bewertung der Prognose können aus den ermittelten Prognosefehlern Konfidenzintervalle für verschiedene Wahrscheinlichkeiten geschätzt werden. Tabelle 17 zeigt, auf dieser Basis für die Vertrauensbereiche von 90%, 95% und 99% die ex ante zu erwartende maximale Fehlergrenze der einzelnen Prognosegrößen.

Größe/Konfidenzintervall	Einheit	90%	95%	99%
Temperatur Innenraum	°C	0,18	0,28	0,65
Temperatur Frontscheibe	°C	0,17	0,25	0,47
rel. Luftfeuchte Kabine	%	0,31	0,48	1,34
Nachlauftemperatur PTC	°C	0,34	0,56	2,55
Lufttemperatur nach Verdampfer	°C	0,04	0,07	0,20
Ausblastemperatur HVAC	°C	0,72	1,24	5,32
Leistung an Verdichterwelle	Watt	4,60	8,46	27,41
Leistung PTC	Watt	26,18	41,44	134,34

Tabelle 18 Konfidenzintervalle der Prognosefehler für verschiedene Wahrscheinlichkeiten

5.2.1.6 Phase 6 - Deployment

Aufgrund der erreichten Abbildungsgüte des Modells kann die sechste Phase der Modellentwicklung, das Deployment, erfolgen. Hierbei wird das Modell zum Einsatz im Gesamtsystem vorbereitet. Für die sechste Phase sind zwei wesentliche Schritte erforderlich. Zunächst muss die Integration des

trainierten Modells in den Optimierungsprozess der Teilfunktion Optimierer erfolgen. Die Beschreibung dieser Integration erfolgt im Kapitel 5.5. Des Weiteren muss das Nachtrainieren des Modells innerhalb der Teilfunktion Trainer gewährleistet werden. Hierfür muss zum einen eine automatische Bereitstellung der Trainingsdaten und zum anderen eine automatische Prozessmodellgenerierung gewährleistet werden. Die automatische Bereitstellung wird durch die Funktion interne Datenverwaltung erfüllt und wird daher im Kapitel 5.3 beschrieben. Zur automatischen Prozessmodellgenerierung ist innerhalb der Teilfunktion Trainer eine weitere Teilfunktion erforderlich.

Diese Teilfunktion muss folgende wesentliche Anforderungen erfüllen:

1. Import einer aktualisierten Datenbasis
2. Import eines vortrainierten Modells
3. Durchführung des Trainingsprozesses der Phase 4
4. Durchführung der Evaluierung der Phase 5
5. Export des nachtrainierten Modells

Im Wesentlichen muss hierbei - neben dem Training - das trainierte Modell, inklusive aller verbundenen Parameter, für zukünftige Trainingsvorgänge und zur Anwendung innerhalb des Optimierers exportiert werden. Ebenso ist der Import von Modell und Lerndatenbasis erforderlich. Diese Import- und Exportfunktionen sind über Schnittstellen der Teilfunktion Trainer zur Teilfunktion externe Datenverwaltung zu realisieren. Des Weiteren ist eine ereignisbasierte Schnittstelle zum Anstoß des Lernvorgangs erforderlich.

Zur weiteren Evaluierung der Funktionalität des Gesamtsystems ist die Implementierung dieser Teilfunktion nicht erforderlich, da hierfür das generierte Modell und die zugehörigen Parameter ausreichend sind. Daher wird im Folgenden auf die Implementierung verzichtet und das Nachtrainieren und Aktualisieren des Prozessmodells nicht-automatisiert ausgeführt.

5.2.2 Modellbildung der Störgrößenmodelle

Das Vorgehen zur Entwicklung der Störgrößenmodelle orientiert sich, wie auch das Vorgehen zur Entwicklung des Prozessmodells, an den in Abbildung 40 aufgeführten Phasen in Anlehnung an das CRISP-DM-Vorgehensmodell. Die Ergebnisse zur Untersuchung zur Vorhersage der Störgrößen wurden im Rahmen dieser Arbeit in [125] veröffentlicht und werden im Folgenden anhand des Vorgehens entlang der Phasen des gewählten Entwicklungsprozesses vorgestellt.

5.2.2.1 *Phase 1 - Process Understanding*

Ziel der Störgrößenprognose es, für den Zeitraum einer bevorstehenden Fahrt die von extern auf das System wirkenden Störgrößen im Sinne eines Bewertungssystems präzise in Ausmaß und Wirkrichtung vorherzusagen. Die Störgrößen korrespondieren mit den äußeren thermischen Lasten durch Konvektion und Strahlung sowie dem Wassereintrag in das System. Diese Lasten werden im Wesentlichen durch den Energieeintrag der solaren Strahlung, der Außentemperatur, der Windgeschwindigkeit und der Luftfeuchte verursacht. Nichtexterne Störgrößen wie z.B. Wassereintrag durch Atmung der Insassen werden durch die Störgrößenprognose nicht berücksichtigt, sondern indirekt durch das Prozessmodell abgebildet. Da die berücksichtigten Störgrößen extern und lokal verursacht werden, muss durch die Prognose der Bezug des räumlichen und zeitlichen Auftretens dieser Störgrößen zum sich bewegenden Fahrzeug hergestellt werden. Hierfür sind Informationen zur Position des Fahrzeugs für jeden Zeitpunkt innerhalb des Prognosefensters erforderlich. Auf Basis der Kenntnis von Position und Zeit kann dann ein Einzelwert für jede Störgröße am betroffenen Ort zur betroffenen Zeit vorhergesagt

werden. Der jeweilige Ort muss dabei anhand eines eindeutigen Bezeichners identifizierbar und damit zuordenbar sein. Hierfür ist eine Diskretisierung der Gesamtstrecke in einzelne Segmente erforderlich. Im Gegensatz zur Vorhersage der Zustands- und Regelgrößen handelt es sich hierbei um keine Zeitreihenprognose, sondern jeweils um eine Serie von Punktschätzungen. Die einzelnen Punktschätzungen müssen dann entlang der Segmente der Fahrstrecke aggregiert, auf die Bezugsgröße Zeit übertragen und so in jeweils eine Zeitreihe für jede zu prognostizierende Störgröße übertragen werden. Der Ansatz zur Vorhersage der Störgrößen ist es, neben den vom Fahrzeug aktuell gemessenen Störgrößen, auf Wetterdaten und Wettervorhersagen externer Dienste zurückzugreifen.

Die relevanten Störgrößen sind, wie bereits erwähnt, die solare Strahlung, die Umgebungstemperatur, die Windgeschwindigkeit sowie die Luftfeuchte. Die Vorhersage dieser Größen ist ein Teilgebiet der wissenschaftlichen Disziplin der Atmosphärenwissenschaften und im Speziellen der Meteorologie. Die Erkenntnisse der Meteorologie finden in diversen Nachbarwissenschaften wie Agrarmeteorologie, Flugmeteorologie, maritime und technische Meteorologie Anwendung. Die Basis der meteorologischen Vorhersagen ist die Synoptische Meteorologie. Hierbei wird ein Netz von Beobachtungsstationen verwendet, die gleichzeitig nach einheitlichen Verfahren Beobachtungen zu festen Terminen durchführen. Die Beobachtungen finden weltweit einheitlich in festgelegten Intervallen statt. Diese Informationen werden durch Radiosondenaufstiege, Satellitenbeobachtungen und Flugzeugmessungen ergänzt. Die gesammelten Daten werden dann in Wetterkarten eingetragen, und dienen zum einen der Ist-Vorhersage (0-2h), dem sogenannten nowcasting, zum anderen auch als Input für numerischen Wettermodelle (NWM) wie z.B. dem globalen GFS-Modell (Global Forecast System) der US-amerikanischen National Oceanic and Atmospheric Administration (NOAA). Mit Hilfe der NWM werden dann wiederum Kurzzeitprognosen (2-12h), Kurzfristprognosen (12-72h) und Mittelfristprognosen (3-10d) durch die Wetterdienste erstellt. [126]

Auf dem Gebiet der Wettervorhersage konnten in den vergangenen Jahren signifikante Fortschritte erzielt werden. Die Qualität der Wettervorhersagen schwankt im Verlauf des Jahres. So können im Sommer, bei stabileren Wetterlagen als im Winter, in der Regel zuverlässigere Prognosen erstellt werden. So lag z.B. der durchschnittliche Prognosefehler des Deutschen Wetterdienstes für die Tageshöchsttemperatur bei einer ein- bis zweitägigen Kurzfristprognose im Jahr 2008 bei 1,6 K. [127]

Die Wetterdienste unterteilen sich in staatliche und private Wetterdienste. Da der überwiegende Teil des Netzes an Beobachtungsstationen durch staatliche Wetterdienste betrieben wird, kaufen die privaten Wetterdienste in der Regel ihre Rohdaten bei den staatlichen Wetterdiensten. Seit den 2000er Jahren haben sich parallel zur verstärkten Nutzung von Informationstechnologien und der massenhaften Verbreitung von Smartphones eine Reihe von Wetterdiensten mit Online-Angebote auf dem Markt mit unterschiedlichen Vermarktungsmodellen etabliert. Hierzu gehören beispielsweise YR (Norwegian Weather Service), DWD (Deutscher Wetterdienst) und Here. Des Weiteren gibt es eine Reihe von barrierefreien Online-Wetterdiensten, wie z.B. Apixu, AccuWeather, Weather Underground und OpenWeatherMap. Diese Dienste bieten Entwicklern von Webdiensten und mobilen Anwendungen aktuelle und historische Wetterdaten sowie Wettervorhersagen. Im Rahmen dieser Arbeit wird zunächst nur die Verwendung von Wetterdaten des frei zugänglichen Online-Wetterdienste OpenWeatherMap untersucht.

Da die so verfügbaren Wetterdaten sowohl örtlich, durch die verfügbaren Beobachtungspunkte, als auch zeitlich, durch den Zeitrahmen der Kurzzeitprognose von 2 Stunden sehr grob aufgelöst sind, ist eine Verfeinerung dieser Prognose für die Bedürfnisse der modellprädiktiven Optimierung

erforderlich. Der Ansatz in dieser Arbeit hierzu ist es, die Verfeinerung auf Basis maschinellen Lernen durchzuführen. Hierfür werden externe Wetterdaten für eine bevorstehende Fahrt erhoben und anschließend in Beziehung zu den durch Durchführung dieser Fahrt gewonnenen Fahrzeugsensordaten gesetzt. Auf dieser Basis werden Störgrößenmodelle trainiert, die anhand der aktuellen Wetterdaten und -vorhersagen und den aktuell gemessenen Störgrößen, die Störgrößen für eine bevorstehende Fahrt präzisieren. Die Störgrößenprognose erfolgt, für jede Störgröße getrennt, jeweils durch ein Modell.

In der folgenden zweiten Phase der Modellbildung erfolgt die Entwicklung einer Methodik zur Datenerfassung aus internen und externen Quellen für die zu entwerfenden Störgrößenprognosen.

5.2.2.2 Phase 2 - Data Understanding

Zur Durchführung der einzelnen Vorhersagen ist es erforderlich, die Segmenteintrittszeiten und die Verweilzeit des Fahrzeugs in diesem Segment vorherzusagen. Diese Vorhersage muss sukzessiv nacheinander für jedes Segment erfolgen, so dass sämtliche Segmente einer Route durchlaufen werden. Zur Durchführung dieser Prognose kann auf Daten des Fahrzeugnavigationssystems zurückgegriffen werden. Diese Systeme verfügen sowohl über eine digitale Karte als auch ein Ortungssystem zur Positionsbestimmung auf dieser Karte. In der digitalen Karte werden in der Regel die Straßensegmente durch Knoten und Kanten repräsentiert, denen wiederum Attribute wie Straßenart, Geschwindigkeitsbegrenzungen etc. zugeordnet werden. Die Zuordnung der aktuellen Position des Fahrzeugs zu einem Segment auf der digitalen Karte erfolgt über mapmatching-Algorithmen.

```
<?xml version="1.0" encoding="UTF-8"?>
- <gpx xmlns:gh="https://graphhopper.com/public/schema/gpx/1.1" version="1.1"
  creator="Graphhopper version 0.10.0"
  xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
  xmlns="http://www.topografix.com/GPX/1/1">
  + <metadata>
  + <rte>
- <trk>
  <name>GraphHopper Track</name>
- <trkseg>
  - <trkpt lon="10.433861" lat="51.902533">
    <time>2018-05-21T21:07:23Z</time>
  </trkpt>
  - <trkpt lon="10.433818" lat="51.902462">
    <time>2018-05-21T21:07:24Z</time>
  </trkpt>
  - <trkpt lon="10.433318" lat="51.902144">
    <time>2018-05-21T21:07:29Z</time>
  </trkpt>
  - <trkpt lon="10.432882" lat="51.901906">
    <time>2018-05-21T21:07:33Z</time>
  </trkpt>
  - <trkpt lon="10.432603" lat="51.901803">
    <time>2018-05-21T21:07:35Z</time>
  </trkpt>
  - <trkpt lon="10.431773" lat="51.901637">
    <time>2018-05-21T21:07:41Z</time>
  </trkpt>
  - <trkpt lon="10.43125" lat="51.901562">
    <time>2018-05-21T21:07:45Z</time>
  </trkpt>
  - <trkpt lon="10.431077" lat="51.901561">
    <time>2018-05-21T21:07:46Z</time>
  </trkpt>
  - <trkpt lon="10.4305" lat="51.901633">
    <time>2018-05-21T21:07:50Z</time>
  </trkpt>
  - <trkpt lon="10.430408" lat="51.901625">
    <time>2018-05-21T21:07:51Z</time>
  </trkpt>
  </trkseg>
</trk>
</gpx>
```

Abbildung 43 Antwort einer Routenplanungsabfrage mit graphhopper

Hierbei werden neben GPS-Koordinaten zusätzliche Signale wie Lenkrichtung und Geschwindigkeit zur Verfeinerung der Positionsbestimmung eingesetzt. Zur Bestimmung eines optimalen Weges wird in Fahrzeugnavigationssystemen ein geeigneter Routenplanungsalgorithmus wie z. B. der Dijkstra-Algorithmus eingesetzt. Im Rahmen dieser Arbeit wurde kein Zugriff auf ein Fahrzeugnavigationssystem realisiert, sondern zur Ermittlung der Routendaten hilfsweise auf die Routing-API der Open-Source-Routing-Bibliothek GraphHopper zugegriffen. Diese basiert auf dem OpenStreetMap-Datenmodell (OSM), welches wiederum auf Knoten (Nodes), Wegen (Ways), Relationen und Tags basiert. Ein Knoten besteht aus einem Punkt im Raum, der durch seine geographische Breite, geographische Länge, Höhe und Knoten-ID eindeutig definiert ist. Wege sind Listen von Knoten zur Darstellung von Straßensegmenten und Flüssen. Relationen sind Listen von Knoten, Wegen und weiteren Relationen zur Darstellung verschiedener Objekte wie z.B. Flächen oder vollständiger Routen. Tags dienen der Verknüpfung der Objekte mit verschiedenen Metadaten. Die GraphHopper-API bietet für eine durch Start und Ziel gegebene Strecke den optimalen Weg in Form einzelner Wegpunkte als OSM-Knoten mit dazugehörigen Zeitpunkten. Abbildung 43 zeigt die Antwort der Routing-API auf eine beispielhafte Routenabfrage.

```

-<current>
  -<city id="2918840" name="Goslar">
    <coord lon="10.43" lat="51.9"/>
    <country>DE</country>
    <timezone>7200</timezone>
    <sun rise="2020-05-30T03:06:19" set="2020-05-30T19:25:46"/>
  </city>
  <temperature value="16.1" min="15.56" max="16.67" unit="celsius"/>
  <feels_like value="14.86" unit="celsius"/>
  <humidity value="51" unit="%"/>
  <pressure value="1024" unit="hPa"/>
  -<wind>
    <speed value="0.45" unit="m/s" name="Calm"/>
    <gusts value="3.13"/>
    <direction value="90" code="E" name="East"/>
  </wind>
  <clouds value="49" name="scattered clouds"/>
  <visibility/>
  <precipitation mode="no"/>
  <weather number="802" value="scattered clouds" icon="03d"/>
  <lastupdate value="2020-05-30T10:07:41"/>
</current>

```

Abbildung 44 Antwort des Wetterdienstes auf die Abfrage des aktuellen Wetters

Hieraus kann eine prognostizierte Verweildauer für jedes Segment und zusätzlich, da die Länge des Segments berechnet werden kann, auch eine prognostizierte Geschwindigkeit im Segment abgeleitet werden. Liegt das Prognoseergebnis der Verweildauer in Form einer Liste der voraussichtlich zu durchfahrenden Segmente und den Ankunftszeiten des Fahrzeugs im jeweiligen Segment vor, kann eine Prädiktion der Störgrößen für jedes dieser Segmente für den antizipierten Zeitpunkt erfolgen. Die Prädiktion erfolgt dabei unter Zuhilfenahme der Wetterdaten von Wetterdiensten. Der Zugriff auf diese Dienste erfolgt ebenfalls per API über eine entsprechende URL. Mit dieser werden verschiedene Parameter der Abfrage, wie z.B. die Koordinaten des Zielortes, an den Dienst übergeben, welcher im Gegenzug die Wetterdaten gebündelt im JSON-, XML- oder HTML- Format übermittelt. Abbildung 44 zeigt die Antworten des Wetterdienstes OpenWeatherMap auf eine Abfrage des aktuellen Wetters, Abbildung 45 die Abfrage einer Wettervorhersage für den geographischen Breitengrad 10,43° und den geographischen Längengrad 51,9°.

```

-<weatherdata>
  -<location>
    <name>Goslar</name>
    <type/>
    <country>DE</country>
    <timezone>7200</timezone>
    <location altitude="0" latitude="51.9043" longitude="10.4277" geobase="geonames" geobaseid="2918840"/>
  </location>
  <credit/>
  -<meta>
    <lastupdate/>
    <calctime>0</calctime>
    <nextupdate/>
  </meta>
  <sun rise="2020-05-30T03:06:18" set="2020-05-30T19:25:48"/>
  -<forecast>
    -<time from="2020-05-30T09:00:00" to="2020-05-30T12:00:00">
      <symbol number="803" name="broken clouds" var="04d"/>
      <precipitation/>
      <windDirection deg="49" code="NE" name="NorthEast"/>
      <windSpeed mps="5.69" unit="m/s" name="Moderate breeze"/>
      <temperature unit="celsius" value="15.84" min="15.4" max="15.84"/>
      <feels_like value="11" unit="celsius"/>
      <pressure unit="hPa" value="1024"/>
      <humidity value="53" unit=""/>
      <clouds value="broken clouds" all="58" unit=""/>
    </time>
    -<time from="2020-05-30T12:00:00" to="2020-05-30T15:00:00">
      <symbol number="500" name="light rain" var="10d"/>
      <precipitation unit="3h" value="0.14" type="rain"/>
      <windDirection deg="49" code="NE" name="NorthEast"/>
      <windSpeed mps="4.6" unit="m/s" name="Gentle Breeze"/>
      <temperature unit="celsius" value="15.93" min="15.84" max="15.93"/>
      <feels_like value="12.05" unit="celsius"/>
      <pressure unit="hPa" value="1024"/>
      <humidity value="56" unit=""/>
      <clouds value="scattered clouds" all="49" unit=""/>
    </time>
  </forecast>
</weatherdata>

```

Abbildung 45 Antwort des Wetterdienstes auf die Abfrage einer Wettervorhersage

Für die Störgrößenprognose werden Wetterdaten entlang der Segmente einer Fahrstrecke benötigt. Hierfür müssen für die einzelnen Koordinatenpaare der Segmente entlang des Fahrweges die Wetterdaten der verschiedenen Wetterdienste abgefragt werden. Die Wetterservices wiederum ordnen die Koordinaten der Abfrage einer einzelnen Wetterstation ihres Beobachtungsnetzes zu und antworten dementsprechend wie in Abbildung 44 gezeigt. Jede Wetterstation der einzelnen Wetterservices ist mit einer eindeutigen Identifikationsnummer und einem eindeutigen Namen gekennzeichnet. Abbildung 46 zeigt verschiedene Wetterstationen des Wetterservices OpenWeatherMap auf der Strecke Goslar-Clausthal.

Die schwarzen Linien zeigen die jeweilige Zuordnung der jeweiligen Wetterstation des Dienstes zu Rasterkoordinaten auf einem Koordinatengitter von 10,3° bis 10,5° geodätischer Länge und von 51,75° bis 51,95° geodätischer Breite. Die durch den Dienst getroffene Zuordnung der Wetterstationen zu Koordinaten der Segmente des Fahrweges ist hierbei jeweils mit einer roten Linie dargestellt. Wie Abbildung 46 erkennbar, sind entlang des Weges von Goslar nach Clausthal bei Streckenlänge von 19 Km nur 4 Wetterstationen des Wetterdienstes betroffen. Daher ist es für eine spätere Störgrößenprognose lediglich notwendig (bei bekannter Zuordnung der Segmente zu den jeweiligen Wetterstationen) für diese Wegstrecke insgesamt 4 Wetterstationen des Wetterdienstes einmalig abzufragen. Die abgefragten Daten können dann wiederum den Segmenten zugeordnet werden.

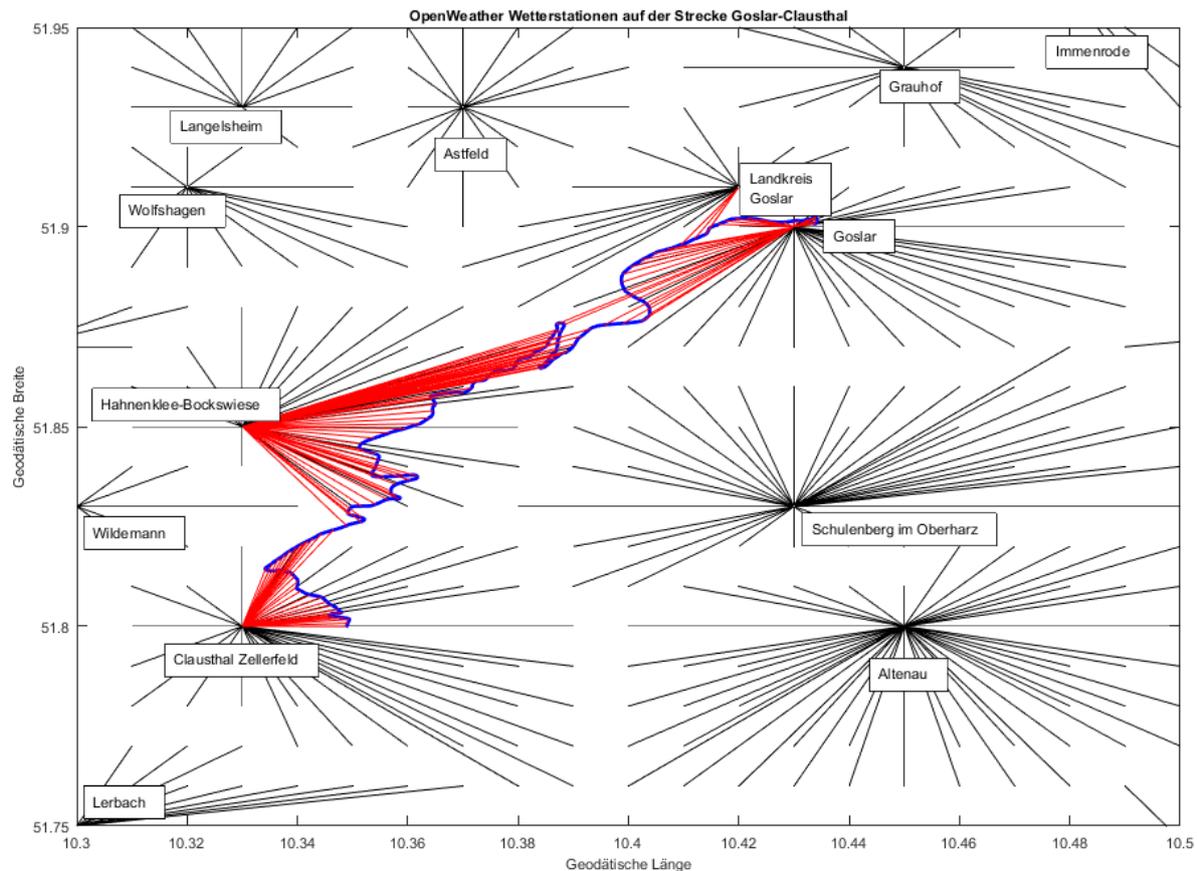


Abbildung 46 OpenWeather-Wetterstationen auf der Strecke Goslar-Clausthal

Neben der Erfassung der Wetterdaten ist der Zugriff auf Messdaten des Fahrzeugs erforderlich. Zur Versuchsdurchführung wurde ein Elektrofahrzeug vom Typ VW-e-Golf eingesetzt. Die Messdaten wurden unter Verwendung eines Datenloggers (Vector GL-3100) aufgezeichnet. Das Fahrzeug ist serienmäßig mit verschiedenen Sensoren zur Aufzeichnung von Klimadaten ausgestattet. Diese sind zum Beispiel verschiedene Temperatursensoren (Frischlufteinlasskanal, Ausblaskanal, Klimabediengerät), Feuchtigkeitssensoren, Sonnenlichtdurchdringungs-Photosensoren sowie der Helligkeitssensor des Scheibenwischers. Die Signale der Sensoren können über die verschiedenen CAN-Busse sowie über die Onboard-Diagnoseschnittstelle (OBD) abgegriffen werden. Da im Falle des Can-Busses die Daten in feineren Zeitrastern mit Zykluszeiten von jeweils 20 bis 200 ms aufgenommen werden können, wurde hierbei auf den CAN-Bus zugegriffen. Zur Fahrzeugmessung wurden Antriebs-, Infotainment- und Komfort-CAN freigeschnitten und mit dem Datenlogger verbunden. Die aufgezeichneten Messdaten des Datenloggers können über WLAN bzw. 3G drahtlos oder über eine SD-Karte manuell übertragen werden. Da die so gewonnenen Messdaten unter anderem in unterschiedlichen Zeitrastern vorliegen, ist eine weitere Vorbearbeitung dieser erforderlich.

Im Rahmen der zweiten Phase des Modellentwicklungsprozesses sollen frühzeitig Probleme der Datenqualität erkannt werden. Daher wurde zunächst die Genauigkeit der prognostizierten Geschwindigkeit durch den Routenplanungsdienst analysiert. Im Rahmen von Fahrzeugmessungen wurde hierbei festgestellt, dass sich diese prognostizierten Zeiten nicht als Grundlage für die folgenden Prädiktionen der Störgrößen eignen.

Abbildung 47 zeigt beispielhaft den Vergleich einer Prognose der Geschwindigkeit durch den Routing-Dienst mit der in einer daraufhin durchgeführten Fahrzeugmessung ermittelten Geschwindigkeit

entlang der sequentiellen Segmente einer Fahrt von Goslar nach Clausthal. Obwohl im Durchschnitt die Ankunftszeit am Zielort relativ gut vorhergesagt wurde, traten in den einzelnen Segmenten sehr starke Abweichungen auf. Dies ist darin begründet, dass, je nach Art der Straße, durch den Planungsalgorithmus eine bestimmte Durchschnittsgeschwindigkeit angenommen wird und individuelle Gegebenheiten wie z.B. das Vorkommen von Ampeln nicht individuell berücksichtigt werden.

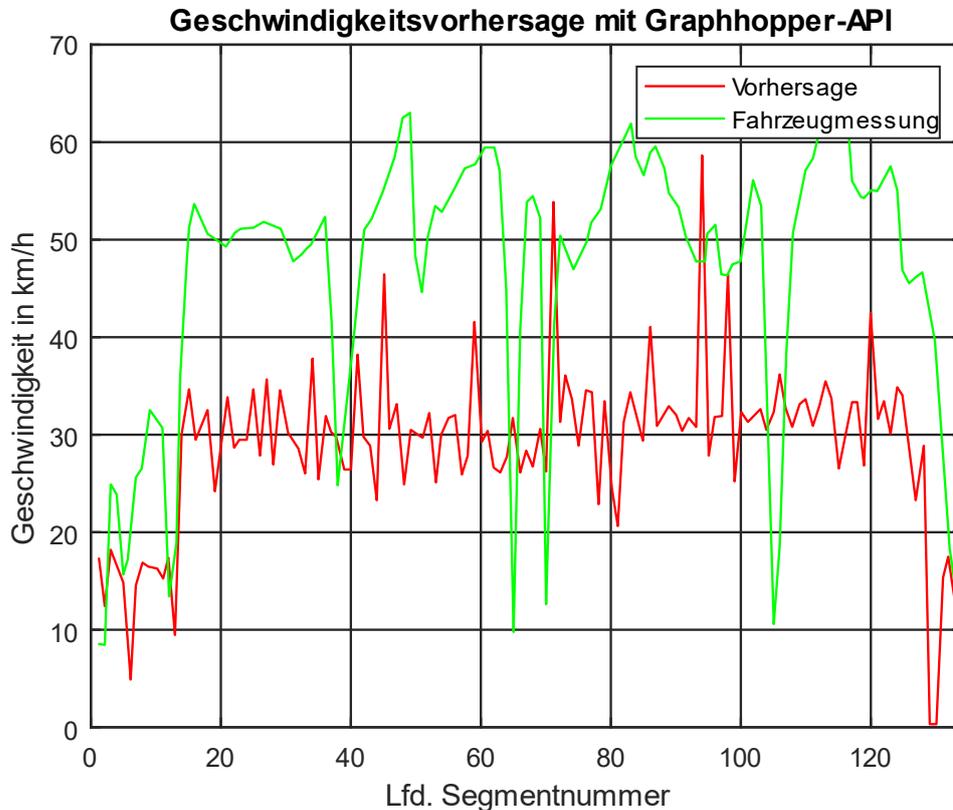


Abbildung 47 Vergleich Geschwindigkeitsprognose GraphHopper mit einer Messung (vgl. [125])

Eine genauere Vorhersage der Verweildauer im Segment ist aber erforderlich, da festgestellt werden muss, wie lange das Fahrzeug der jeweiligen Störgröße, wie z.B. der Sonnenstrahlung, im individuellen Segment ausgesetzt ist. Hierfür ist eine weitere Prognosefunktion auf der Basis maschinellen Lernens erforderlich, die sowohl Ankunftszeit und Verweildauer, als auch die Geschwindigkeit im jeweiligen Segment präzisiert.

5.2.2.3 Phase 3 - Data Preparation

In der dritten Phase des Modellbildungsprozesses erfolgt die Auswahl des Modellierungsverfahrens und die Erstellung des Trainingsdatensatzes. Wie in 5.2.2.1 festgestellt, ist eine hohe Anzahl an Einzelmodellen erforderlich, da für jede Störgröße für jedes zu durchzufahrende Segment eine einzelne Punktschätzung erfolgen muss. Da die einzelnen Prognosen eine Art Verfeinerung bzw. Präzisierung der Mess- und Wettervorhersagedaten darstellen, ist eine hohe Korrelation von Eingangs- und Ausgangsdaten zu erwarten. Für die zugrunde liegenden Probleme sind eine Reihe von Methoden des maschinellen Lernens prinzipiell geeignet, die sich allerdings in Berechnungsaufwand, Generalisierungsfähigkeit, Konvergenzverhalten und Speicherbedarf unterscheiden. Aufgrund der hohen Anzahl der benötigten Modelle werden im Folgenden Verfahren gewählt, die einen möglichst geringen Trainingsaufwand im Sinne des Berechnungsaufwandes aufweisen. Hierzu zählen Methoden der multivariaten Regression und k-nearest-neighbor-Algorithmen. Für die Modellauswahl und Festlegung der

Modellstruktur ist hierbei ein ständiges zyklisches Wechselspiel zwischen Datenvorbereitung, Modellierung und Evaluation erforderlich. Im Gesamtsystemzusammenhang erfolgt die Datenvorbereitung allerdings sequentiell innerhalb der Teilfunktion Lokale Datenverwaltung. Daher wird die zur Modellstrukturfindung erforderliche Datenvorbereitung im folgenden Unterkapitel zur Modellierung und die spätere Datenvorbereitung im Gesamtsystemkontext im Kapitel 5.3 diskutiert.

5.2.2.4 Phase 4 - Modeling

In dieser Phase erfolgt die Modellbildung der einzelnen Störgrößenmodelle. Im Folgenden wird die Modellbildung zur Prognose der Verweildauer im Segment, zur Prognose der Umgebungstemperatur sowie der solaren Strahlung erläutert. Da im Fahrzeug keine Sensorik zur Wahrnehmung der Windgeschwindigkeit vorhanden ist, kann eine Prognose dieser nicht auf einer fahrzeugdatenbasierten Methode des Maschinellen Lernens erfolgen¹⁹. Die Windgeschwindigkeit beeinflusst den konvektiven Wärmestrom zwischen Fahrzeughülle und Umgebung, da sie neben der Geschwindigkeit des Fahrzeugs auch die Strömungsgeschwindigkeit der Luft an der Außenhülle und damit den Wärmeübergangskoeffizient der Konvektion bestimmt. Untersuchungen zum Einfluss der Windgeschwindigkeit auf das Wärmeübertragungsverhalten der Fahrzeughülle übersteigen allerdings den Rahmen dieser Arbeit. Daher wird die Windgeschwindigkeit im Folgenden vernachlässigt. Des Weiteren wird auf die Erläuterung der Modellbildung zur Prognose der Luftfeuchtigkeit verzichtet, da das zu verwendende Verfahren exakt dem der Umgebungstemperaturprognose entspricht.

5.2.2.4.1 Geschwindigkeit und Verweildauer

Wie in der zweiten Phase festgestellt, ist eine verbesserte Prognose der Geschwindigkeit und Verweildauer des Fahrzeugs erforderlich. Hierfür existieren bereits eine Reihe von Verfahren die eine hohe Prädiktionsgenauigkeit erreichen (vgl. [128] und [129]). Die Entwicklung eines Verfahrens zur Geschwindigkeitsprognose ist allerdings kein eigentliches Ziel dieser Arbeit, da dieses organisatorisch dem Navigationssystem zuzuordnen ist und die Geschwindigkeitsprognose in späteren Entwicklungszyklen über die Schnittstellen der externen Datenverwaltung zu empfangen ist. Da diese noch nicht realisiert sind, wird folgend hilfsweise ein einfaches Verfahren zur Verbesserung der Geschwindigkeitsprognose entwickelt.

Die Fahrzeuggeschwindigkeit in einem Segment steht in Verbindung mit Fahrzeugtyp, Fahrweise, Verkehrslage, Straßentyp, Straßengeometrie und möglichen Hindernissen, wie z.B. Ampeln oder Baustellen. Hierbei wird angenommen, dass diese Einflussgrößen im Wesentlichen mit dem Zeitpunkt der Fahrt zusammenhängen und ähnlichen Mustern unterliegen. Während der Straßentyp und Straßengeometrie relativ konstant bleiben, variieren die anderen Faktoren eher stärker. Dem folgenden Ansatz liegt die Vermutung zugrunde, dass die Geschwindigkeit des Fahrzeugs neben dem Fahrverhalten und Straßensegment hauptsächlich der Tageszeit und dem Wochentag unterliegt. Daher soll in Abhängigkeit von Segment, Uhrzeit und Wochentag eine Verweildauer in diesem Segment vorhergesagt werden.

$$\begin{aligned}
 V: S \times T \times D &\rightarrow R && (141) \\
 S &\subseteq \mathbb{Z} && \text{Segment ID} \\
 T &= \{0..86400\} \quad T \subseteq \mathbb{Z} && \text{Laufende Zeit des Tages in Sekunden} \\
 D &= \{1..7\} \quad D \subseteq \mathbb{Z} && \text{Wochentag} \\
 R &\subseteq \mathbb{R} && \text{Verweildauer}
 \end{aligned}$$

¹⁹ ohne Erweiterung der entsprechenden Messsensorik

Zur Prognose der Verweilzeit wird ein Distance-Weighted k-Nearest-Neighbor-Verfahren (wkNN) verwendet, welches erstmalig in [130] veröffentlicht wurde. Der wkNN-Algorithmus ist einer der einfachsten maschinellen Lernalgorithmen und ist aufgrund der zahlreichen zu erlernenden Segmente gut geeignet. Diese Lernverfahren werden auch als instanzbasierte Lernverfahren oder auch lazy learning bezeichnet. Die Prognose erfolgt nicht auf Basis eines Trainingsvorgangs, sondern wird direkt aus der Datenbasis ermittelt. Der Merkmalsraum besteht hierbei aus allen aggregierten Messdaten für das jeweilige Segment. Er besteht aus den Dimensionen Segment, laufende Tageszeit und Wochentag. Die Ausgabe besteht aus der Zusammenfassung der Eigenschaftswerte. Dies sind die Geschwindigkeiten der k engsten Trainingsbeispiele im Merkmalsraum. Die normierte euklidische Distanz wird als Distanzmetrik verwendet. Da der Merkmalsraum in beiden Dimensionen zyklisch ist - der Montag (hier mit der 1 belegt) liegt neben dem Sonntag (mit 7 belegt) - wurde der Merkmalsraum an den Rändern durch Kopien des gegenüberliegenden Randes erweitert. Für die k-Eigenschaftswerte wird gemäß ihrem Abstand (Distanz d_n), ein Gewicht w

$$w_n = \frac{\frac{1}{d_n}}{\sum_{i=1}^k \frac{1}{d_i}} \quad (142)$$

berechnet. Unter Verwendung der Gewichte der k-nächsten Nachbarn im Eigenschaftsraum, wird der resultierende Gesamtwert

$$r_{pred} = \sum_{i=1}^k w_i * r_i \quad (143)$$

berechnet. Die Prädiktion erfolgt einzeln nacheinander für sämtliche Segmente einer bevorstehenden Fahrt. Zur Berechnung der Segmenteintrittszeit des folgenden Segments t_{k+1} wird die erhaltende Verweildauer r_{pred_k} des letzten Segments auf die Segmenteintrittszeit des letzten Segments aufaddiert:

$$t_{k+1} = t_k + r_{pred_k}. \quad (144)$$

Über die prognostizierte Verweildauer kann unter Hinzunahme der Segmentlänge eine prognostizierte Geschwindigkeit im Segment abgeleitet werden. Wie Abbildung 48 zeigt, liegt die Güte der Ergebnisse bereits wesentlich über der Güte der ursprünglichen Routenplanung.

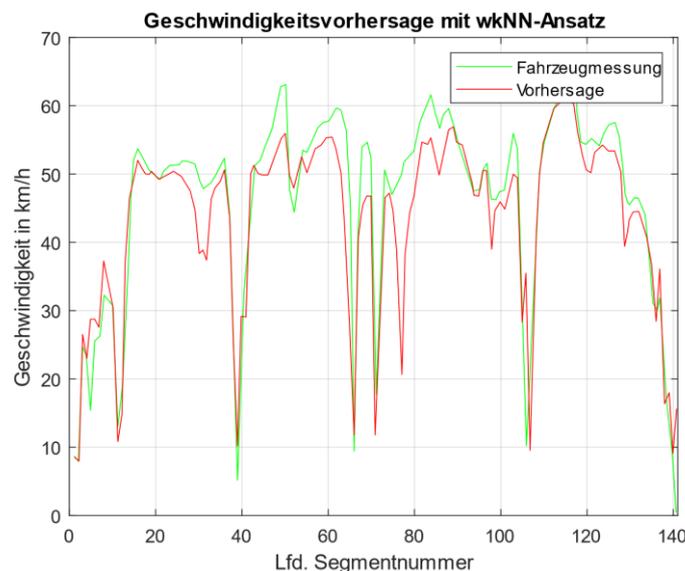


Abbildung 48 Geschwindigkeitsprognose mit wkNN-Ansatz (vgl. [125])

5.2.2.4.2 Temperatur

Ziel der Temperaturprognose ist es, auf Basis von Wetterdaten von Wetterdiensten die lokale Temperatur in einem spezifischen Segment für einen spezifischen Zeitpunkt vorherzusagen. Hierfür wurde zunächst nur der Dienst OpenWeatherMap ausgewertet. Abbildung 49 zeigt einen Vergleich der jeweiligen abgefragten Wetterdaten mit den aus 34 Messfahrten aufgenommenen Messdaten für ein spezifisches Segment. Der Wert auf der X-Achse entspricht hierbei dem vorhergesagten Wert, der Wert auf der Y-Achse dem der Vorhersage zugehörigen Messwert. Wie in der Abbildung ersichtlich, kommt es zum Teil zu starken Abweichungen im Vergleich zur perfekten Vorhersage. In der Mehrzahl der Messungen liegt der tatsächliche Messwert der Fahrzeugmessung zwischen der aktuellen Temperaturabfrage des Wetterdienstes und dem nowcast-Wert (0-3h). Eine Vermutung zur Ursache dieser Abweichungen ist der Zeitversatz zwischen Prognosezeitpunkt²⁰ bzw. Messzeitpunkt der Wetterstation und Messzeitpunkt der Fahrzeugmessung.

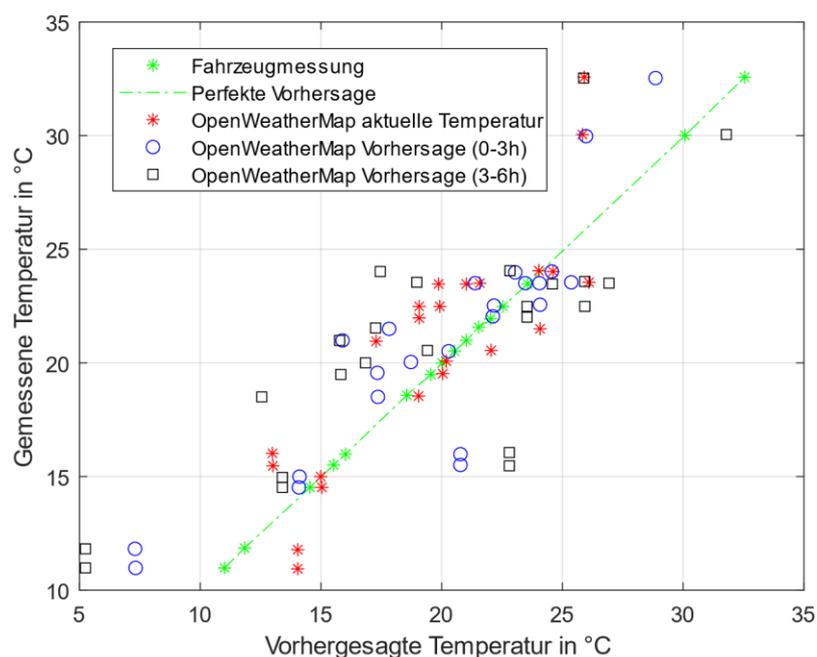


Abbildung 49 Vergleich abgefragter Wetterdaten mit Fahrzeugmessdaten

Abbildung 50 zeigt den zeitlichen Versatz zwischen dem Prognosezeitpunkt und dem Zeitpunkt des tatsächlichen Erreichens des Segments für die 34 Messfahrten. Wie auf der Abbildung ersichtlich, ist z.B. für die Messung Nr. 15 der Zeitversatz zur aktuellen Temperatur (roter Stern) negativ. Der Wert liegt dementsprechend in der Vergangenheit und ist um 45 Minuten veraltet. Die Vorhersagewerte für 0-3 Stunden (blauer Kreis) und 3-6 Stunden (schwarzes Rechteck) sind positiv, liegen also 5 Minuten bzw. 225 Minuten in der Zukunft. Da die Vorhersagewerte sich auf eine Zeitfenster von 3 Stunden beziehen, wurde zur Ermittlung des Versatzes der Abstand zum Mittelpunkt des jeweiligen Intervalls (nach 90 Minuten) verwendet.

²⁰ Der Zeitpunkt auf den die Prognose bezogen ist.

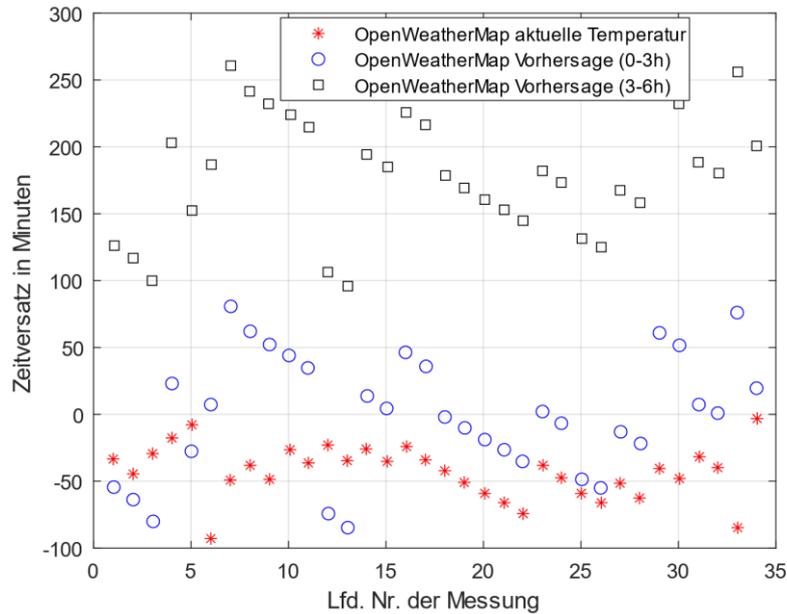


Abbildung 50 Zeitlicher Versatz von Vorhersagezeit und Messung

Dem folgenden Ansatz liegen nun zwei Vermutungen zu Grunde. Die erste Vermutung ist, dass je nach Entfernung des Segments von der Wetterstation bzw. zum aktuellen Fahrzeugstandort, sich die Temperatur zum selben Zeitpunkt t_0 nur um einen festen Offset unterscheidet. Demnach kann die Temperatur für diesen Zeitpunkt $T_{Segment}(t_0)$ aus der Temperatur der nahen Wetterstationen und dem Fahrzeug ermittelt werden. Die zweite Vermutung ist, dass sich die Temperatur über einen begrenzten Zeitraum mit konstanter Steigung ändert. Der Temperaturwert im Segment setzt sich demnach aus der Temperatur zum Vorhersagezeitpunkt und der Veränderung der Temperatur bis zum Erreichen des Segmentes zusammen:

$$T_{Segment}(t_{arrival}) = T_{Segment}(t_0) + (t_{arrival} - t_0) * \Delta T_{Segment}. \quad (145)$$

Die Steigung der Temperaturänderung im jeweiligen Segment, bis zum Ankunftszeitpunkt des Fahrzeugs in diesem, wird folglich aus der Wettervorhersage geschätzt. Hierbei wird die Änderung der Temperatur

$$\Delta T_{Segment} = \frac{T_{Prognose}(t_2) - T_{Prognose}(t_1)}{t_2 - t_1} \quad (146)$$

innerhalb des Prognosefensters der Vorhersage verwendet. Basierend auf diesen Annahmen können die Features der Lernfunktion abgeleitet werden. Dies sind, neben dem aktuellen Temperaturmesswert des Fahrzeugs, die aktuelle Temperatur der nächsten Messstationen sowie die aus der Temperaturvorhersage abgeleitete Veränderung der Temperatur der Messstation. Zur Berücksichtigung des zeitlichen Versatzes wird für jeden dieser Werte ein Gewicht entsprechend der Differenz aus Vorhersagezeitpunkt und vorhergesagter Ankunftszeit im Segment berechnet. Wettervorhersagen mit weitem Prognosehorizont werden hierdurch weniger stark gewichtet als Wettervorhersagen mit nahem Prognosehorizont und Messwerten. Unter Verwendung der Gewichte der benannten Temperaturparameter erfolgt nun eine multiple lineare Regressionsanalyse für die Modellgleichung

$$y = b_0 + \sum_{i=1}^2 b_i * w_i * T_i + \sum_{i=2}^4 b_i * w_i * \Delta T_i \quad (147)$$

durch einen Least-Square-Algorithmus. Auf Basis dieser Modellstruktur wurde anschließend jeweils für jedes Segment auf der Teststrecke zwischen Goslar und Clausthal ein Modell zur Punktschätzung der Segmenttemperatur anhand der 34 Messfahrten trainiert und mit den Messdaten von drei Testfahrten getestet. Hierbei konnten keine befriedigenden Testergebnisse erzielt werden. Im Rahmen einer Analyse dieses Ergebnisses wurden die durch den Wetterdienst erhaltenen Temperaturdaten für die Messstation Clausthal mit Daten der Wetterstation des Instituts für elektrische Messtechnik abgeglichen. Hierbei wurden signifikante Abweichungen festgestellt. Daher wurden die Temperaturmesswerte der Openweathermap-Wetterdaten für Clausthal durch Temperaturmesswerte des Instituts für elektrische Messtechnik ersetzt. Hierbei wurde jeweils der Temperaturmesswert der Station in Clausthal zum Zeitpunkt des Starts der Messfahrt in Goslar verwendet. Anschließend wurde das System neu trainiert und getestet.

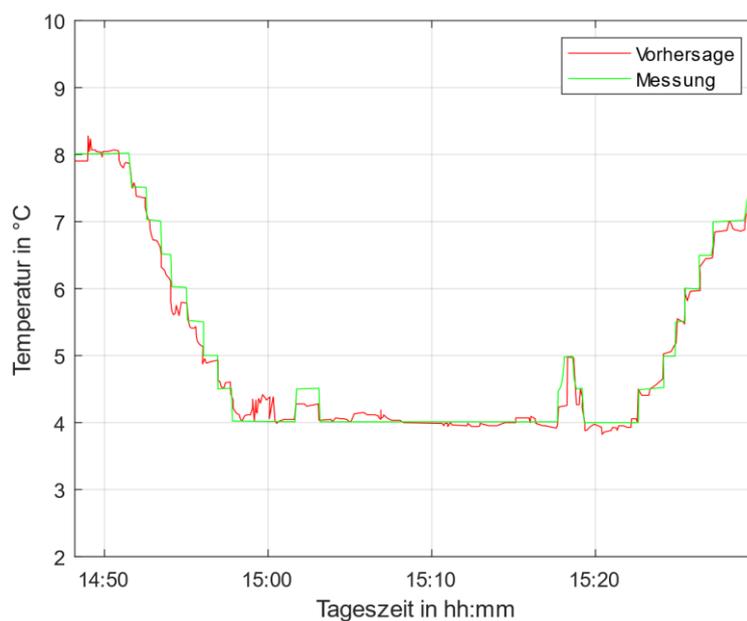


Abbildung 51 Vergleich von Messung und Temperaturvorhersage (vgl. [125])

Abbildung 51 zeigt die Ergebnisse der Vorhersage und Messung für einen Testlauf von Goslar nach Clausthal und zurück. Beide Orte haben einen Höhenunterschied von 300 Metern, was die starke Temperaturänderung erklärt. Es wurden zwei zusätzliche Testläufe durchgeführt, die ähnliche Ergebnisse ergaben. Eine grobe Einordnung der Qualität der Prognose kann anhand eines Benchmarkwerts wie z.B. der naiven Prognose erfolgen. Naive Prognosen werden im Allgemeinen in zwei Typen unterschieden. Der erste Typ der naiven Prognose (No-Change-Prognose) verwendet den aktuellen Wert zur Schätzung aller zukünftigen Werte. Der zweite Typ (Same-Chance-Prognose) verwendet ebenfalls den aktuellen Wert, addiert aber in jedem Prognoseschritt die Differenz zwischen aktuellem und letztem Wert auf. Als Benchmarkwert wird im Folgenden der erste Typ der naiven Prognose verwendet. Dieser entspricht im vorliegenden Fall dem ersten gemessenen Temperaturwert einer Fahrt.

Zur Quantifizierung des Fehlers eignet sich der quadratische Mittelwertfehler (RMSE). Die 3 Testläufe hatten einen durchschnittlichen RMSE von 0,151, was signifikant unter der naiven Prognose (RMSE 3,325) und der Auflösung des Originalsignals (RMSE 0,5 K) liegt.

5.2.2.4.3 Solare Strahlung

Der Energieeintrag durch solare Strahlung ist im Wesentlichen abhängig von der relativ konstanten Strahlungsleistung der Sonne, vom Winkel der Sonneneinstrahlung, dem Ausmaß an atmosphärischer Reflexion und Absorption, der Bewölkung und der Position von schattengebenden Objekten. Die Sonnenstrahlung setzt sich hierbei aus direkter und indirekter Strahlung zusammen. Die Prädiktion der solaren Strahlung stellt sich insofern schwierig dar, als dass hier kein Wert eines Wetterdienstes direkt verwendet werden kann. Die Wetterdienste liefern lediglich eine Beschreibung und Vorhersage der Bewölkung in Form einer skalaren Bewertung von 0 bis 100. Untersuchungen auf den Gebieten der Agrarmeteorologie [62] und regenerativen Energiesysteme [60] zeigen aber, dass der Anteil der direkten Strahlung sehr gut berechnet werden kann, wenn die Position der Sonne relativ zum Standort bekannt ist. Tritt allerdings diffuse Sonnenstrahlung auf, welche das Sonnenlicht aufgrund von Hindernissen, Nebel oder Wolken streut, ist die Bestrahlungsstärke kaum direkt zu berechnen. Im folgenden Ansatz wird davon ausgegangen, dass die solare Bestrahlungsstärke maßgeblich von Sonnenposition, Bewölkung und Standort des Fahrzeugs abhängig ist. Die Reduktion des Energieeintrags der solaren Strahlung durch schattengebende Hindernisse (Gebäude, Pflanzen und Bäume) hängt maßgeblich von der Sonnenposition und der Fahrzeugposition ab und ist demnach lernbar.

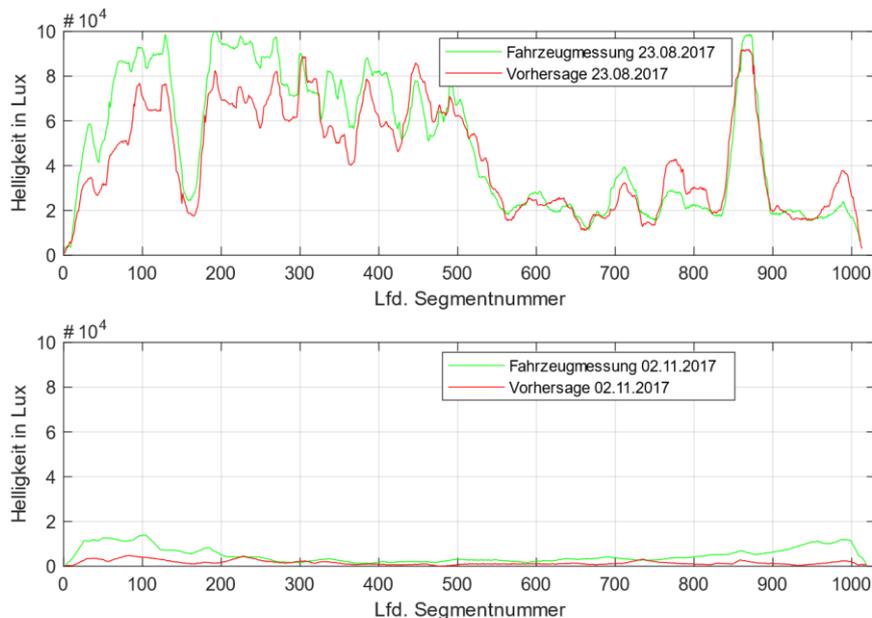


Abbildung 52 Vorhersage und Messung der solaren Strahlung (vgl. [125])

Die Beschreibung der Position der Sonne erfolgt durch die Angabe von Azimut und Sonnenhöhe. Azimut und Sonnenhöhe können mit den in 5.2.2.4.1 bereits prädierten Werten für Ort und Zeit direkt berechnet werden (vgl. [60]). Die Eingangsgrößen für den Prädiktionsalgorithmus sind demnach Sonnenstand, beschrieben durch Azimut und Sonnenhöhe, sowie der vorhergesagte Bewölkungsgrad durch den Wetterdienst. Als Trainingsdaten wurden im ersten Ansatz die in Abschnitt 5.2.2.1 erwähnten aufgezeichneten und aggregierten Signale des Helligkeitssensors der Scheibenwischerregelung verwendet. Als Lernverfahren wird der distance-weighted k-nearest-neighbor-Ansatz aus 5.2.2.4.1 verwendet. Das System wurde wieder mit den Messdaten aus 34 Fahrzeugmessungen trainiert und anhand von 3 Fahrzeugmessungen getestet. Abbildung 52 zeigt Vorhersage und Messung von zwei der Testfahrten mit jeweiliger hoher bzw. niedriger solaren Strahlung. Hierbei wird ersichtlich, dass der

Verlauf der auf das Fahrzeug einwirkenden Strahlung relativ gut prädiziert wird, es im absoluten Betrag aber zu teilweise hohen Abweichungen kommt.

Ursache hierfür ist die zu geringe Zahl an Trainingsdaten. Die zum Training verwendeten Testdaten wiesen eine geringere Bewölkung auf, wodurch die möglichen Konstellationen von Bewölkung und Sonnenstand nicht ausreichend in der Trainingsmenge abgebildet wurden. Die Vorhersage für die Testläufe ergab einen durchschnittlichen RMSE von 1131,2, was signifikant unter dem durchschnittlichen RMSE einer entsprechenden naiven Prognose (RMSE 5499,4) liegt.

5.2.2.5 *Phase 5 - Evaluation*

Die Qualität der Vorhersage thermischer Störgrößen hängt stark von der Qualität der Wettervorhersage sowie von der Qualität und Quantität der Trainingsdaten ab. Die verfügbaren Daten des getesteten barrierefreien Online-Wetterdienstes sind als Basis für eine präzise Vorhersage der Störgrößen nur bedingt geeignet. Daher ist es erforderlich, die Datenqualität weiterer verfügbarer Wetterdienste zu überprüfen und diese in das Prognoseverfahren einzubinden. Des Weiteren ist eine deutlich höhere Zahl an Trainingsdaten zur Abbildung der möglichen thermischen Umgebungsbedingungen durch die Prognosemodelle erforderlich. Eine qualifizierte und statistisch aussagefähige Evaluation ist durch die erfolgten Testfahrten nicht möglich. Hierfür ist eine deutliche höhere Anzahl an Messdaten notwendig. Diese könnten zum Beispiel im Rahmen einer Fahrzeugflottenmesskampagne erhoben werden. Die Evaluation der so erhobenen Daten kann dann durch die Erhebung und Bewertung der in Kapitel 5.2.1.5 aufgeführten Metriken erfolgen.

5.2.2.6 *Phase 6 - Deployment*

Innerhalb der sechsten Phase wird der Einsatz der Prädiktionsverfahren im Gesamtsystem vorbereitet. Hierbei müssen zum einen die Anwendung der Verfahren innerhalb der Teilfunktion Prädiktor und zum anderen das Nachtrainieren der Modelle innerhalb der Teilfunktion Trainer gewährleistet werden. Aufgrund der hohen Anzahl der Modelle und der eingesetzten Verfahren unterscheiden sich die Anforderungen hierbei von denen des Deployments des Prozessmodells. Aufgrund der Verwendung von instanzbasierten Verfahren ist zur Erstellung der Prognosen, die Suche im Merkmalsraum der Trainingsdaten erforderlich. Hierfür ist der Zugriff auf eine Datenbank erforderlich. Das Training erfolgt hierbei durch Erweiterung des Merkmalsraums durch Hinzufügen neu gemessener Klima- und Messdaten, daher müssen hierfür keine Modellparameter gespeichert oder übertragen werden. Für die Ablage dieser Daten ist ebenfalls ein Zugriff auf diese Datenbank erforderlich. Durch den Trainingsvorgang der Regressionsmodelle werden die 5 Parameter der Regressionsgleichung neu bestimmt. Das Training muss für jedes einzelne Segment der Datenbank durchgeführt werden. Für die Umsetzung der Regressionsverfahren ist ein Vorgehen in Analogie zu 5.2.2.6 erforderlich. Hierbei ist eine weitere Teilfunktion zur automatischen Regressionsmodellgenerierung innerhalb der Teilfunktion Trainer erforderlich, die folgende Anforderungen erfüllen muss:

1. Import einer aktualisierten Datenbasis
2. Durchführung des Trainingsprozesses der Phase 4
3. Durchführung der Evaluierung der Phase 5
4. Export des nachtrainierten Modells

Der Zugriff auf die Datenbasis sowie deren Erweiterung wird im folgenden Kapitel zur lokalen und externen Datenverwaltung erläutert. Die Beschreibung des Einsatzes der Störgrößenmodelle erfolgt im Kapitel 5.4.

5.3 Lokale und externe Datenverwaltung

5.3.1 Abruf, Aufbereitung und Bereitstellung der Trainingsdaten

5.3.1.1 *Daten des Prozessmodells*

Zum Training des Prozessmodells werden die Ein- und Ausgangsgrößen gemäß Tabelle 4 benötigt. Diese müssen in Form vom in Kapitel 5.2.1.3 beschriebenen 3D-Dataframe-Format in Sequenzen für die einzelnen Messfahrten zusammengefasst und aufbereitet werden. Die Erhebung der zum Training benötigten Messdaten erfolgte im Rahmen der Arbeit über einen Datenlogger vom Typ Vector GL3100. In späteren Entwicklungszyklen muss diese Datenerhebung über eine direkte Kommunikation mit den betroffenen CAN-Bussen erfolgen und in die Teilfunktion lokale Datenverwaltung integriert werden.

Zur Fahrzeugmessung wurden Antriebs-, Infotainment- und Komfort-CAN des Referenzfahrzeugs freigeschnitten und mit dem Datenlogger verbunden. Die Messdaten wurden vom Datenlogger im nachrichtenbasierten blockorientierten Dateiformat BLF (Binary Logging Format) gespeichert und unter Verwendung des Werkzeugs Vector-Logger-Configurator in das Matlab-Dateiformat MAT konvertiert. Hiernach liegt die Fahrzeugmessung in Form von jeweils einer zweidimensionalen Matlab-Matrize für jedes Messsignal vor. Die Matrizen bestehen jeweils aus einem Zeitstempel und einem Messwert für jeden Abtastzeitpunkt des Signals. Die Zykluszeiten der Abtastungen der einzelnen Signale unterteilen sich jeweils in Zeitraster von 20, 100 und 200 Millisekunden. Da für die Trainingsdaten ein Zeitraster von 2 Sekunden erforderlich ist, wurden die Zeitreihen der Messwerte auf das entsprechende Zeitraster transformiert und auf ein Zeitfenster von 1800 Sekunden zugeschnitten. Das eingesetzte LSTM-Verfahren unterstützt zwar Eingabedaten unterschiedlicher Sequenzlänge, schneidet allerdings während des Trainingsvorgangs alle Sequenzen des jeweiligen Mini-Batches auf die Länge der kürzesten Sequenz ab. Hiernach wurden die einzelnen Matrizen in eine Matlab-Zellstruktur im in Kapitel 5.2.1.3 beschriebenen 3D-Dataframe-Format transformiert und durch ein concat-Verfahren an den Initiallern Datensatz angehängt. Hierfür musste der Initiallern Datensatz geladen, bearbeitet und wieder im Matlab-Dateiformat MAT abgelegt werden. Die Verbreitung und Übermittlung der so gewonnenen Trainingsdaten ist nach Abschluss jeder durchgeführten Fahrt einmalig auszuführen.

5.3.1.2 *Daten der Störgrößenmodelle*

Das Verfahren zur Aufbereitung der Ein- und Ausgangsgrößen der Modelle zur Störgrößenprognose gestaltet sich im Vergleich zur Aufbereitung der Lerndaten des Prozessmodells deutlich aufwendiger. Zu Beginn jeder Fahrt müssen die Wetterdaten und Wettervorhersagen für die bevorstehende Streckenführung erhoben werden. Die instanzbasierten Lernverfahren erfordern die Ablage der aus Mess- und Wetterdaten gewonnenen Trainingsdaten in einer Datenbank. Die Datenbank ist der Teilfunktion extern Datenverwaltung zuzuordnen. Hierfür ist ein Datenmodell erforderlich, dessen Herleitung im Zusammenhang mit der Bearbeitung der Mess- und Wetterdaten im Folgenden diskutiert werden soll.

Wie in Kapitel 5.2.2 beschrieben, erfolgt die Prädiktion der Störgrößen für eine anstehende Fahrt in Form einer Aneinanderreihung von Prädiktionen für die separaten Straßenabschnitte der zu absolvierenden Strecke. Dieser Straßenabschnitte werden in dieser Arbeit als Segment bezeichnet. Ein Segment besteht hierbei immer aus 2 Knoten. Für die Knoten werden direkt die Koordinaten der in OSM definierten Knoten übernommen. Ein Knoten besteht aus einem Punkt im Raum, der durch Breiten- und Längengrad definiert ist. Jedes Segment ist durch eine individuelle ID (SID) eindeutig zuordenbar. Eine Fahrt erfolgt auf einer definierten Strecke. Jeder Fahrt als auch jeder Strecke werden ebenfalls eindeutige IDs zugeordnet (FID und STID). Jede Strecke besitzt einen Anfangs- und Endknoten. Für jede Strecke sind mehrere Wege möglich, da ein Zielort, ausgehend vom Startort, über unterschiedliche

Wege erreicht werden kann. Jeder Strecke ist mindestens ein Weg zugeordnet. Jeder Weg ist durch eine festgelegte Reihenfolge der zu durchfahrenden Segmente eindeutig festgelegt. Die Beobachtungspunkte der Wetterdienste werden als Service bezeichnet und sind durch eine serviceeigene ID (SEREIG_ID) eindeutig gekennzeichnet. Jeder Service liefert 3 verschiedene Servicetypen, welche durch eine individuelle Service-ID (SERID) eindeutig gekennzeichnet sind. Dies sind *Wetterabfrage* (aktuelles Wetter), *Prognose_1* (0-3 h) und *Prognose_2* (3-6 h). Jedem Segment werden die 3 Servicetypen mindestens eines Services zugeordnet. Abbildung 53 veranschaulicht die hier bisher verwendeten Definitionen graphisch.

Zu Beginn einer jeden Fahrt ist die Eingabe des Fahrziels durch den Benutzer erforderlich. Hierdurch ist, in Kombination mit der durch das Ortungssystem bestimmten aktuellen Position die zu absolvierende Strecke festgelegt. Durch die Routenplanung kann der Weg und damit die zu durchfahrenden Segmente bestimmt werden.

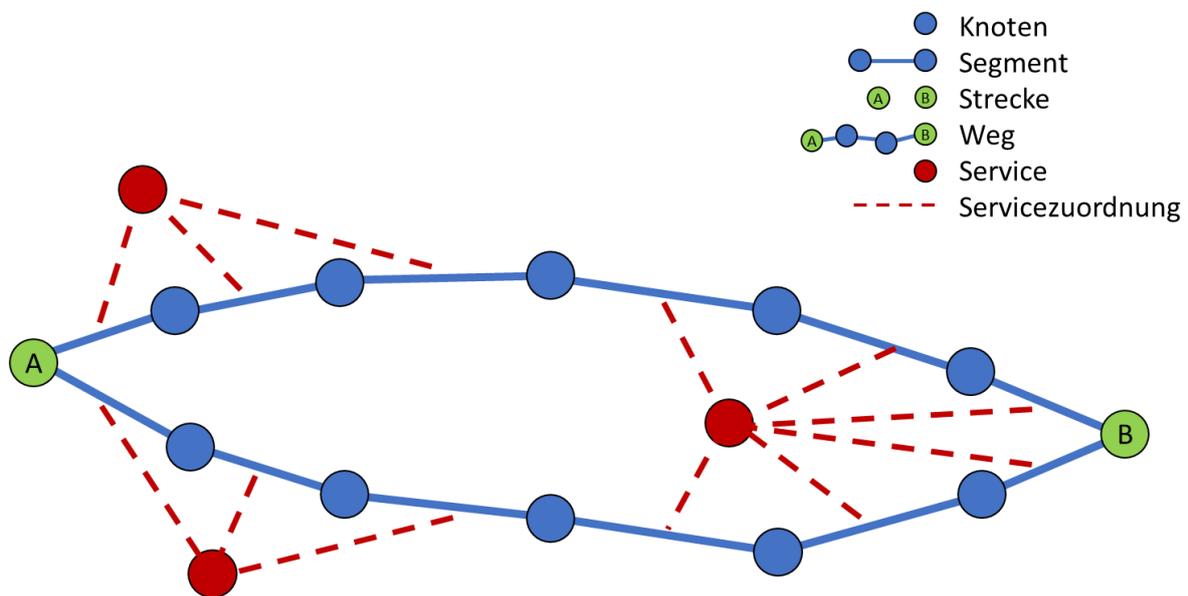


Abbildung 53 Graphische Darstellung der verwendeten Definitionen

Zur späteren Zuordnung von Mess- und Wetterdaten ist für jede geplante Fahrt der zugeordnete prognostizierte Weg, Start- und Zielzeit sowie eine eindeutige ID (FID) zu speichern. Hierfür ist ein Element im Datenmodell erforderlich, welches im Folgenden als *Fahrt* bezeichnet wird.

Für jedes Segment des Weges können nun, durch Abfrage der Segment-Service-Zuordnung, die zugehörigen Servicetypen der Services ermittelt werden. Hierdurch wiederum können alle benötigten Serviceabfragen abgeleitet werden. Für eine Strecke vom Standort DIGIT Goslar zum Standort ISSE Clausthal ergeben sich z.B. 12 Serviceabfragen. Wie in Abbildung 46 ersichtlich, ergeben sich diese aus den jeweils drei Servicetypen der vier Services mit den Beobachtungspunkten „Goslar“, „Landkreis Goslar“, „Hahnenklee-Bockswiese“ und „Clausthal Zellerfeld“. Über die API des Wetterdienstes können anschließend die betroffenen Services abgefragt werden. Aus der Antwort des Dienstes können dann die Einzelwerte der relevanten Wetterdaten ausgelesen und abgelegt werden. Zur Speicherung der Daten ist ein weiteres Element im Datenmodell erforderlich, welches im Folgenden als *Service_Abfrage* bezeichnet wird.

Neben den Wetterdaten sind zum Training der Störgrößenprognosemodelle zusätzlich Messdaten des Fahrzeugs erforderlich. Hierbei werden die aus dem BLF-Format konvertierten Messdaten im Matlab-Dateiformat verwendet (vgl. 5.3.1.1). Diese Messdaten werden in einem ersten Verarbeitungsschritt so organisiert, dass für eine Fahrt jedem gemessenen Zeitpunkt im 200ms-Zeitraster ein Vektor aus Zeitstempel, geographischer Länge, geographischer Breite, Umgebungstemperatur, Helligkeitswert der Strahlung, Luftfeuchtigkeit und Fahrzeuggeschwindigkeit zugeordnet wird. In einem weiteren Verarbeitungsschritt wird jeder dieser Vektoren einem bekannten Segment zugeordnet. Hierfür muss jeweils immer sichergestellt werden, dass die Segmente bereits im Rahmen der Prognose registriert wurden. In Abhängigkeit von Fahrzeuggeschwindigkeit und Zeitraster sowie Länge des Segments variiert die Anzahl von Messpunkten pro Segment. Abbildung 54 zeigt ausschnittsweise, für einen Teil einer durchgeführten Fahrt den Ort der Messpunkte (schwarze Punkte) und die zuzuordnenden Segmente (farbige Linie mit Segmentnummer).

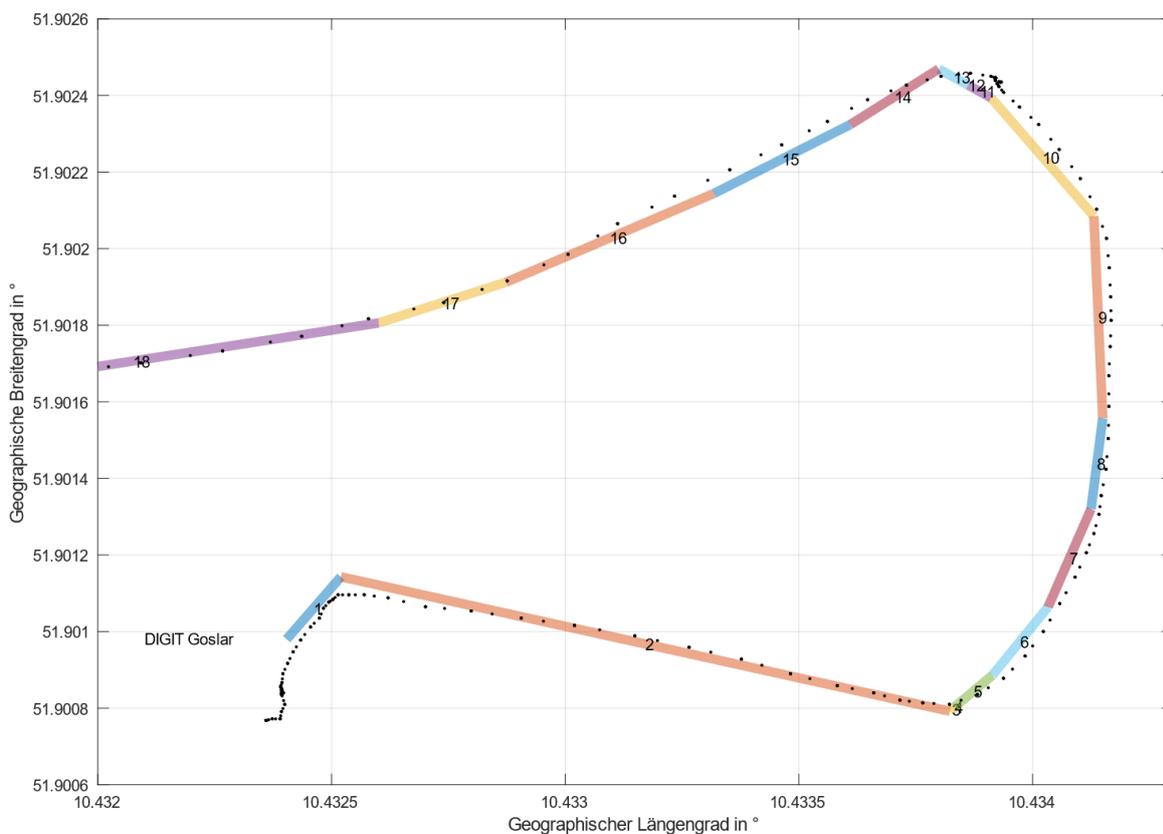


Abbildung 54 Messpunkte und Segmente einer Beispielfahrt

Die Zuordnung der Messpunkte zu den Segmenten erfolgt mittels Mapmatching-Algorithmus unter Berücksichtigung der Entfernung des Messpunktes zum Mittelpunkt des Segmentes und der Segmentlänge. Wird für ein prognostiziertes Segment kein Messwert gemessen, kann dieses Segment später nicht belehrt werden. Im folgenden Verarbeitungsschritt wurden die einem Segment zugeordneten Messwerte jeweils zu einem einzelnen gemittelten Messwert x_S je Messgröße pro Segment aggregiert. Hierdurch ergibt sich für den Messwert

$$x_S = \frac{\sum_{i=1}^n t_i * x_i}{\sum_i t_i} \quad (148)$$

Zur späteren Zuordnung von Mess- und Wetterdaten ist jede durchgeführte Fahrt mit dem zugeordneten (aus der Messung ermittelten) Weg und einer eindeutigen ID (FID) zu speichern. Hierzu wird das Element *Fahrt* genutzt. Prognose- und Messfahrten werden dabei durch den Typ der Fahrt (Prognose/Messung) unterschieden. Zur Speicherung der Messdaten des Fahrzeugs ist ein weiteres Element im Datenmodell erforderlich, das im Folgenden als *Kerntabelle* bezeichnet wird. Hierbei sind neben den für die Messwerte erforderlichen Attribute, Attribute zur Zuordnung des jeweiligen Segmentes auf dem Weg, als auch der Identifikation der Messfahrt (FID) erforderlich. Abbildung 55 zeigt den Ausschnitt des bis hierher abgeleiteten Teil des Datenmodells.

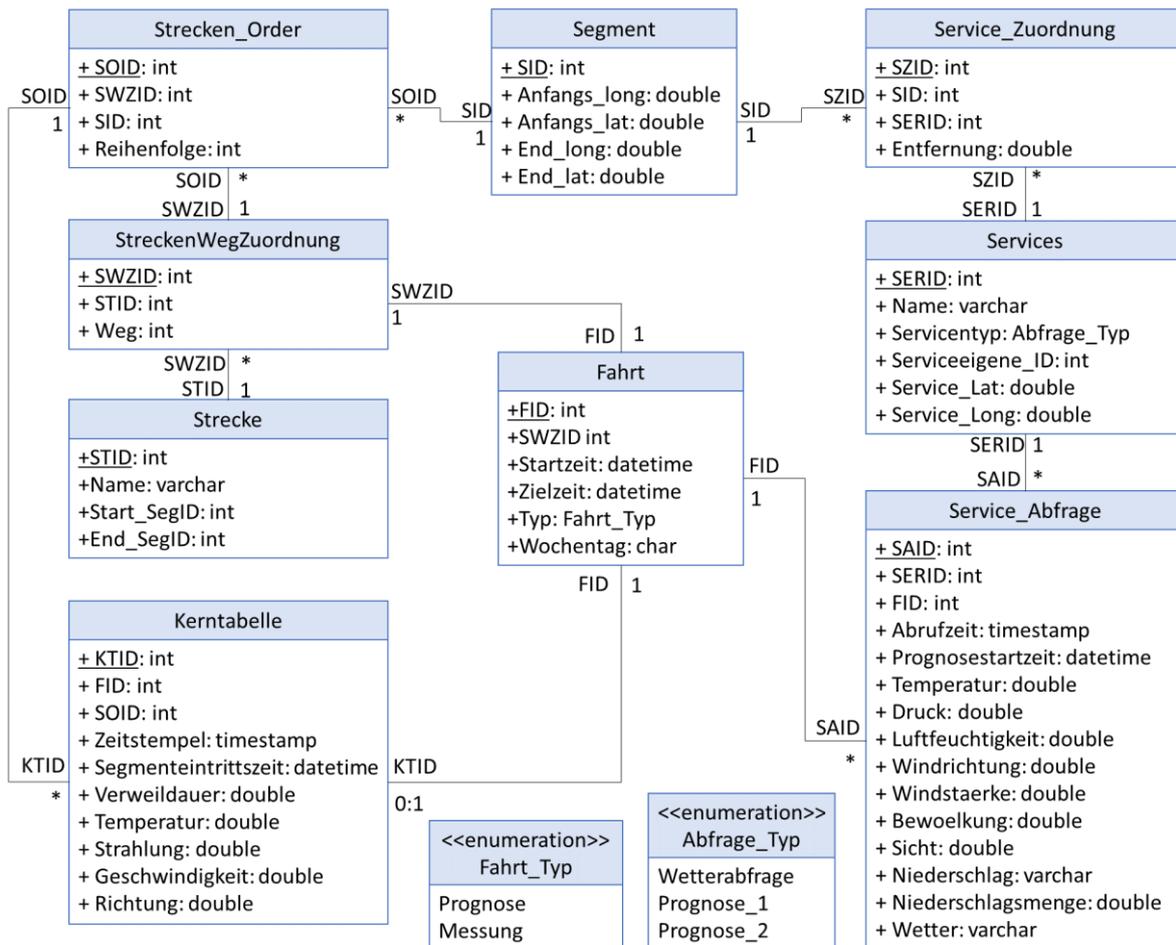


Abbildung 55 Datenmodell zur Ablage der Wetter- und Messdaten

Aus den so aufbereiteten Mess- und Wetterdaten können die Trainingsdaten abgeleitet werden. Zusätzlich zu den aus Messung und Abfrage der Wetterdienste gewonnenen Informationen zu Temperatur und Luftfeuchtigkeit müssen noch Zeitversatz der einzelnen Prognose- und Abfragewerte sowie die prognostizierten Steigungen der Vorhersagegrößen abgeleitet werden (vgl. Formel 145 bis Formel 147). Zur Prognose der solaren Strahlung muss für jedes Segment aus der antizipierten Ankunftszeit in diesem, Azimut und Sonnenhöhe berechnet werden. Hiernach stehen die Trainingsdaten zur Störgrößenprognose bereit. Die Trainingsdaten werden für jede Störgrößenprognose getrennt, separaten Elementen des Datenmodells zugeordnet (vgl. Anhang A.10).

5.3.2 Abruf, Aufbereitung und Bereitstellung der Prognoseinputdaten

Neben der Bereitstellung der Trainingsdaten sind Abruf, Aufbereitung und Bereitstellung der zur Durchführung der Prognosen zur Systemlaufzeit erforderlichen Prognoseinputdaten erforderlich. Diese Prozessschritte sind ebenfalls der Teilfunktion lokale Datenaufbereitung zuzuordnen. Da die Bereitstellung der Prognoseinputdaten des Prozessmodells zeitlich nach der Störgrößenprognose erfolgt, werden die erforderlichen Arbeitsschritte im Folgenden entsprechend dieser Reihenfolge erläutert.

Die Verarbeitung der Prognoseinputdaten erfolgt entsprechend der Reihenfolge der Verarbeitung der Trainingsdaten, da diese die Prognoseinputdaten beinhalten. Der wesentliche Unterschied liegt hierbei im jeweiligen Zeitpunkt der Bereitstellung der Daten. Während für die Trainingsdaten eine einmalige Bereitstellung nach der Fahrt ausreichend ist, müssen die Prognoseinputdaten zur Systemlaufzeit zyklisch den verarbeitenden Funktionen zur Verfügung gestellt werden.

Durch Abfrage der Routendaten des Navigationssystem, muss zunächst die geplante Strecke als auch die Streckenführung ermittelt werden. Hieraus wird eine Liste entsprechend der Reihenfolge der zu durchfahrenden Segmente abgeleitet. Für jedes Element dieser Liste wird - bei zusätzlicher Berücksichtigung der aktuellen Zeit - die in Kapitel 5.2.2.4.1 beschriebene Prognose der Verweildauer und Geschwindigkeit ausgeführt. Zusätzlich erfolgen entsprechend den Elementen in der Liste die Abfrage der betroffenen Services, Aufruf der Serviceabfrage und Ablage der so gewonnenen Wetterdaten in der Datenbank. Hierauf aufbauend können die Eingänge zur Störgrößenprognose für jedes Segment ermittelt werden. Zur Prognose der solaren Strahlung ist die Berechnung von Azimut und Sonnenhöhe sowie der aus den Wetterdaten abgeleitete skalare Bewölkungswerte für jedes Segment erforderlich. Zur Prognose von Temperatur und relativer Luftfeuchtigkeit sind, neben den Abfragewerten dieser Größen, die Steigungen aus den Vorhersagen und die jeweiligen Zeitversätze zu ermitteln. Nach Bereitstellung der Prognoseinputgrößen können innerhalb der Teilfunktion Prädiktor die einzelnen Prognosen für alle Segmente des bevorstehenden Weges durchgeführt werden. Innerhalb der Teilfunktion Prädiktor werden die Prognoseinputgrößen des Prozessmodells ermittelt und der Teilfunktion Modellprädiktiver Optimierer in der einspeisbaren Form bereitgestellt.

Im weiteren Verlauf der Regelung wird der Prognosehorizont verschoben. Jede neue Prognose der Regel- und Zustandsgrößen durch das Prozessmodell innerhalb der Teilfunktion Modellprädiktiver Optimierer erfolgt ausgehend von einem späteren Zeitpunkt und damit ausgehend von einem veränderten thermischen Zustand des Systems. Der aktuelle thermische Zustand des Systems wird innerhalb des LSTM-Netzes durch die Werte der zustandsspeichernden Elemente der Zellen (cell state und hidden state) repräsentiert. Daher müssen diese zu Beginn jedes neuen Prognosefensters aktualisiert werden. Die Aktualisierung des Netztes erfolgt durch Propagation gemessener Eingangsgrößen durch das Netz. Hierfür müssen diese Messwerte der Teilfunktion Modellprädiktiver Optimierer durch die Teilfunktion lokale Datenverwaltung bereitgestellt werden. Diese Messwerte werden, wie in 5.3.1.1 beschrieben, durch die lokale Datenverwaltung blockweise geloggt und in die einspeisbare Form transformiert.

5.4 Prädiktion von Stell- und Störgrößen

Innerhalb der Teilfunktion Prädiktor erfolgt die Prognose der Stell- und Störgrößen, die Aufbereitung in eine durch das Prozessmodell nutzbare Form sowie die Bereitstellung dieser. Hierbei werden die einzelnen Prognosen für alle Segmente des bevorstehenden Weges durchgeführt. Die Durchführung erfolgt für die Prädiktion der Umgebungstemperatur und relativen Luftfeuchtigkeit nach dem in Kapitel 5.2.2.4.2 beschriebenen Verfahren. Hierfür müssen für jedes Segment die 5 Parameter der Regressionsgleichung über eine Schnittstelle empfangen werden. Die Prädiktion erfolgt durch Anwendung der Regressionsgleichung auf die bereitgestellten Prognoseinputdaten für jedes Segment sukzessiv. Die Durchführung der Prädiktion der Strahlung erfolgt nach dem in Kapitel 5.2.2.4.3 beschriebenen instanzbasierten Verfahren für jedes Segment. Da die Ergebnisse der Prognosen segmentbezogen sind, müssen diese anschließend in eine Zeitreihe mit einem Zeitraster von 2 Sekunden umgewandelt werden. Hierfür wird ein Interpolationsverfahren eingesetzt. Neben den zukünftigen Verläufen der Störgrößen werden des Weiteren die zukünftigen Verläufe der nicht durch diese Regelung beeinflussbaren Stellgrößen benötigt.

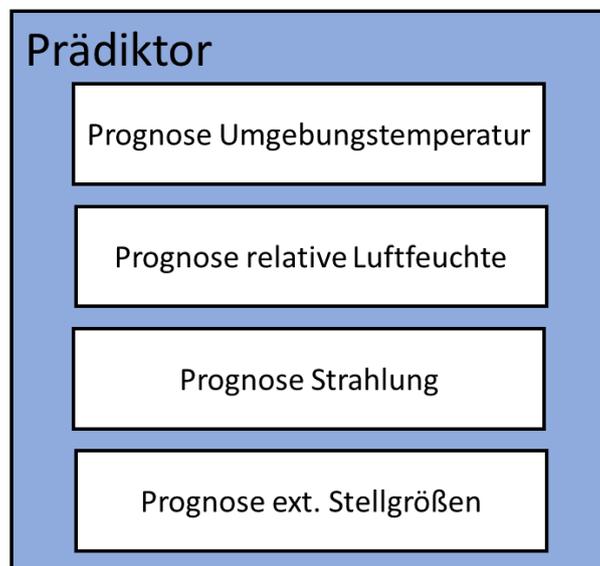


Abbildung 56 Untergliederung der Teilfunktion Prädiktor

Dies betrifft im vorliegenden Fall den Verlauf der Stellung der Umluftklappe, sowie den Verlauf der Frischluftgebläsestufe. Hierbei wird im Folgenden angenommen, dass die hierfür verwendeten Regelungsverfahren bekannt sind und damit die Verläufe aus der Störgrößenprognose abgeleitet werden können. Für die folgenden Versuche werden, wie auch in der Situationsanalyse, beide Stellgrößen auf konstante Werte eingestellt. Nach Zusammenführung der Prädiktionen der externen Stellgrößen und der Störgrößen stehen die Zeitreihen der zukünftigen Eingänge des Prozessmodells zur Verfügung. Diese Zeitreihen müssen anschließend in das erwähnte 3D-Dataframe-Format in Sequenzen transformiert werden. Hiernach liegen die Prognoseinputgrößen des Prozessmodells in einer für das LSTM-Netz einspeisbaren Form vor. Da das Netz zu Beginn der Fahrt auf den vorkonditionierten Initialzustand trainiert ist, kann hiermit die Prognose der Regel- und Zustandsgrößen für den ersten Prognosehorizont erfolgen.

5.5 Modellprädiktive Optimierung

Innerhalb der Teilfunktion Modellprädiktiver Optimierer erfolgt die Optimierung der Trajektorien für die Stellgrößen Temperaturklappe und ACC-Zustand sowie die Bereitstellung der Stellfolge der Stellgrößen zur Regelung innerhalb des Heizungs-, Lüftungs- und Klimaanlageansystems für den Zeitraum bis zum Prognosehorizont. Die hierfür benötigten Teilfunktionen werden entsprechend dem Grobkonzept den Teilfunktionen Prozessmodell, Kritiker und Optimierungssteuerung zugeordnet.

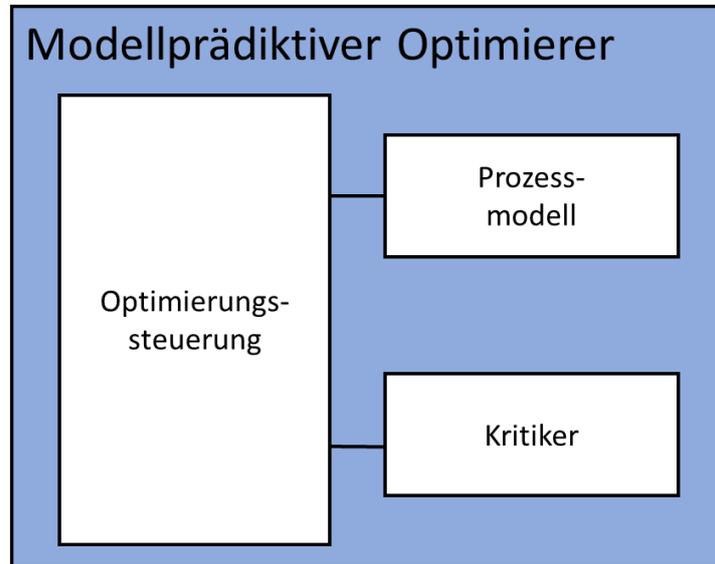


Abbildung 57 Untergliederung der Teilfunktion Modellprädiktiver Optimierer

Das jeweilige Optimum wird hierbei durch Optimalitätskriterien festgelegt. Da eine analytische Lösung der zugrundeliegenden Optimierungsaufgabe nicht möglich ist, wird hierbei im eigentlichen Sinne keine optimale Trajektorie bestimmt, sondern eine Approximation an eine optimale Trajektorie durchgeführt. Zur Durchführung der Optimierung ist es erforderlich, ein Optimierungsproblem zu formulieren und ein geeignetes Optimierungsverfahren zur Lösung des formulierten nichtlinearen Optimierungsproblems zu identifizieren. Das Optimierungsproblem muss aus dem Prozessmodell, den Regelzielen und Nebenbedingungen hergeleitet werden. Das Prozessmodell entspricht dem in Kapitel 5.2.1 beschriebenen trainierten LSTM-Netz. Die Regelziele und Nebenbedingungen können z.T. aus den in Tabelle 6 und Tabelle 7 erstellten Metriken abgeleitet werden. Die Regelziele bestehen zum einen in dem Erreichen der Soll-Innentemperatur der Kabine und zum anderen in der Minimierung der zur Klimatisierung aufgewendeten Gesamtenergie. Wie in Kapitel 2.2 erläutert, kann die Minimierung des Energiebedarfs durch Minimierung der energierelevanten Stellgrößen u oder Minimierung des Stellaufwandes Δu erreicht werden. Beide Regelziele widersprechen sich, da zur Erreichung der Solltemperatur in der Regel immer Energie aufgewendet werden muss. Deshalb müssen für beide Terme zusätzliche Gewichtungparameter μ eingeführt werden. Die Kombination beider Regelziele ergibt eine Zielfunktion in Form der Gleichung

$$J_R = \mu_1 \sum_{n=1}^{n_p} (T_{Ist}(n) - T_{Soll}(n))^2 + \mu_2 \sum_{n=1}^{n_p} (\Delta tk_n)^2 + (\Delta ACC_n)^2. \quad (149)$$

Die Laufvariable i der Summenfunktion ist hierbei der diskrete Zeitschritt im 2-Sekundenraster. Der Endwert n_p entspricht dem Prognosehorizont. Die Stellaufwände Δtk_i und ΔACC_i entsprechen der Differenz der aktuellen Werte der Stellgrößen im jeweilige Zeitschritt zum jeweils vorangegangenen

Wert. Neben den Regelzielen müssen zur Formulierung des Optimierungsproblems die Nebenbedingungen berücksichtigt werden. Dies kann durch Einbeziehung von Lagrange-Multiplikatoren (vgl. Kapitel 2.2.3) oder durch Erweiterung der Zielfunktion um Straf- und/oder Barriereterme erfolgen. Die Umsetzung der Einbeziehung der Nebenbedingungen ist stark vom verwendeten Optimierungsverfahren abhängig, weshalb dieses zunächst diskutiert werden soll.

Prinzipiell sind zwei grundsätzliche Vorgehensweisen zum Lösen der Optimierungsaufgabe denkbar. Das ist zum einen ein numerischer und zum anderen ein metaheuristischer Ansatz. Bei einem numerischen Ansatz sind wiederum zwei mögliche Vorgehensweisen denkbar. So könnte das in Form eines Berechnungsgraphen vorliegende Prozessmodell in ein Gleichungssystem transformiert werden. Hieraus könnte dann, wie in Kapitel 2.2.3 beschrieben, ein Optimierungsproblem abgeleitet und dieses durch ein direktes Mehrfachschießverfahren zur numerischen Lösung von Optimalsteuerungsproblemen, wie z.B. in [76] und [84] vorgestellt, gelöst werden. Alternativ hierzu könnte der Berechnungsgraph des LSTM-Netzes direkt genutzt werden. Hierzu müssten zur Einbeziehung der Nebenbedingungen, Straf- und Barriereterme formuliert und der Zielfunktion hinzugefügt werden. Der Berechnungsgraph könnte dann, analog zur Lossfunktion, um eine Schicht am Ausgang zur Berechnung der Zielfunktion erweitert werden. Hiermit kann dann durch ein Verfahren des Automatischen Differenzierens im Rückwärtsmodus (vgl. Kapitel 2.1.4.2) ein Gradient durch die partiellen Ableitungen nach den Stellgrößen berechnet werden. Die Matlab Deep Learning Toolbox bietet zum Beispiel zur Berechnung der Gradienten die Funktionen `dlgradient` und `dlfeval` an. Ein Problem der numerischen Ansätze kann aus der Konvexität der Zielfunktion resultieren. Ist die Zielfunktion nicht konvex, besteht die Gefahr des Verharrens an einem lokalen Optimum, so dass das globale Optimum nicht gefunden werden kann.

Eine Alternative zu numerischen Lösungsansätzen bieten metaheuristische Optimierungsverfahren. Diese Verfahren basieren auf einer methodischen Suche im Lösungsraum aller möglichen Lösungen und werden daher auch als globale Optimierungsverfahren bezeichnet. Die Größe des Lösungsraum hängt im vorliegenden Fall von der Diskretisierung der Stellgrößen und der Anzahl der Zeitschritte bis zum Prognosehorizont n_p ab. Bei einer Auflösung des Temperaturklappenstellsignals von 0,01 im Wertebereich von 0 bis 1 sowie zweier möglicher Zustände des ACCs und einem Prognosehorizont von 1800 Sekunden mit einem Zeitraster von zwei Sekunden ergeben sich bereits 200^{900} mögliche Lösungen. Metaheuristische Ansätze eignen sich zur Lösungssuche in derart komplexen Lösungsräumen. Häufig eingesetzte metaheuristische Optimierungsverfahren sind naturinspirierte bzw. naturanaloge Optimierungsverfahren wie Bergsteigeralgorithmus, Ameisenalgorithmus, simulierte Abkühlung, Partikelschwarmalgorithmus und genetische bzw. evolutionäre Algorithmen. Entsprechend des bereits im Rahmen der Auswahl des Lernverfahrens diskutierten No-Free-Lunch-Theorem, gibt es allerdings kein Verfahren, das generell für jegliche Problemstellung am besten geeignet ist. Ein Problem metaheuristischer Optimierungsansätze besteht darin, dass das Finden einer optimalen bzw. zufriedenstellenden Lösung nicht garantiert werden kann. Ist das Stellgesetz der konventionellen Regelung allerdings bekannt, kann dieses Problem beschränkt werden. Die Trajektorien der konventionellen Regelung bei gleichen Umgebungsbedingungen können dann ermittelt und durch das Prozessmodell und Gütefunktional ebenfalls bewertet werden. Durch den Vergleich beider Lösungen und der Auswahl der überlegenen Lösung, kann so sichergestellt werden, dass mindestens die Güte der konventionellen Regelung erreicht wird. Metaheuristische Optimierungsverfahren bieten eine Reihe von Vorteilen gegenüber numerischen Algorithmen. Sie sind auch für nichtkonvexe Optimierungsprobleme geeignet und benötigen keine Ableitungen. Ein weiterer Vorteil metaheuristischer Verfahren gegenüber numerischen

Verfahren ist, dass das Modell als Black-Box gekapselt betrachtet werden kann, weshalb ein hierauf basierender Lösungsansatz ausgewählt wird.

Aus der Gruppe der metaheuristischen Algorithmen eignen sich evolutionäre Algorithmen besonders gut zur Kombination mit einem lernenden Verfahren. Durch die stochastische Komponente evolutionärer Algorithmen finden diese oft eine Lösung dicht an der optimalen Lösung. In Verbindung mit einem lernenden Verfahren stellt dies einen Vorteil dar, da durch die stochastische Komponente so die Umgebung um die optimalen Betriebspunkte erkundet werden kann. Durch die Einstellung der so gefundenen Lösungen und Beobachtung der Ergebnisse kann das Verhalten des Systems dicht am Optimum gelernt werden. Des Weiteren sind evolutionäre Algorithmen sehr gut parallelisierbar und daher zur Kombination mit der ebenfalls gut parallelisierbaren Modellprädiktion durch ein LSTM-Netz geeignet. Evolutionäre Algorithmen gehören zur Gruppe der Anytime Algorithmen und stellen auch bei vorzeitigem Abbruch des Verfahrens eine Lösung zur Verfügung [131]. Im Folgenden wird daher ein Lösungsansatz basierend auf evolutionären Algorithmen entwickelt.

Evolutionäre Algorithmen sind vom Prinzip der natürlichen Evolution von Lebewesen abgeleitet. Die Verarbeitungsschritte dieser Algorithmen entsprechen daher den wesentlichen biologischen Evolutionsfaktoren Selektion, Mutation und Rekombination. Einzelne Lösungen einer Optimierungsaufgabe entsprechen den Individuen einer Population. Die Gesamtheit aller Individuen einer Population zu einem Zeitpunkt entspricht einer Generation. Durch einen Selektionsprozess werden die geeignetsten Individuen einer Generation bestimmt (Selektion). Die Auswahl erfolgt aufgrund der Fitness der Individuen, welche wiederum durch eine Zielfunktion bestimmt wird. Die Zielfunktion entspricht hierbei dem Gütefunktional der modellprädiktiven Regelung. Die fittesten Individuen einer Generation werden miteinander kombiniert und erzeugen so eine neue Population (Rekombination). Durch anschließende Mutationen innerhalb der neuen Population werden den einzelnen Individuen weitere Merkmale hinzugefügt und damit die Genvielfalt der Population erhöht. Hierdurch entsteht eine neue Generation die den Evolutionsprozess erneut durchläuft.

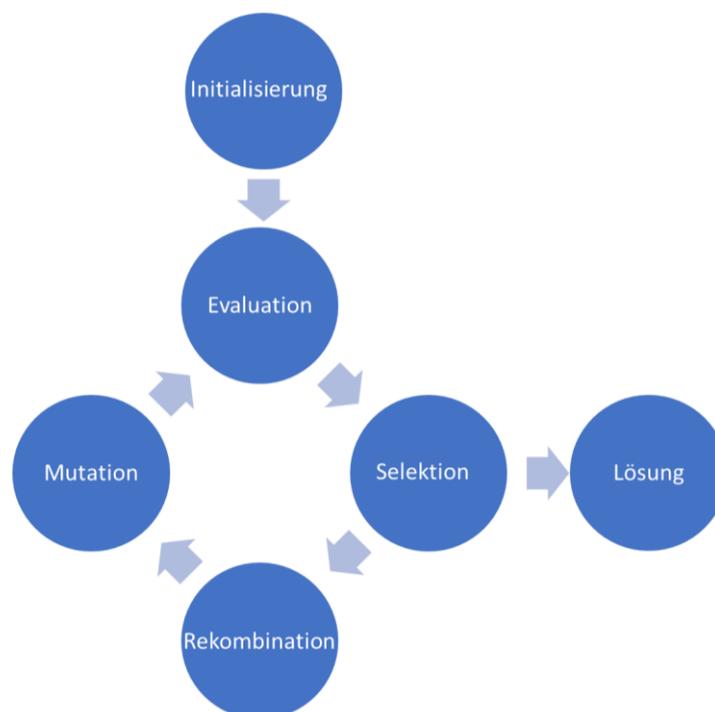


Abbildung 58 Prinzipieller Ablauf evolutionärer Algorithmen

Ausgehend von einer durch eine Initialisierung gewonnenen Startpopulation wird der Evolutionsprozess so lange durchlaufen, bis ein Abbruchkriterium erreicht wird. Das Abbruchkriterium kann hierbei auf Konvergenzverhalten, Rechenzeit, Anzahl der Generationen oder erreichter Fitness beruhen. Abbildung 58 veranschaulicht den groben Ablauf des Verfahrens. Eine detaillierte Beschreibung evolutionärer Algorithmen findet sich in [132].

Der Ansatz zur Umsetzung der Modellprädiktiven Optimierung ist es, innerhalb der Teilfunktion Optimierungssteuerung auf der Basis eines evolutionären Algorithmus ein Optimierungsverfahren umzusetzen. Dieses Optimierungsverfahren ermittelt unter Verwendung des trainierten LSTM-Netzes sowie einer Zielfunktion eine optimierte Trajektorie der Stellgrößen. Das trainierte LSTM-Netz wird durch die Teilfunktion Prozessmodell bereitgestellt. Die Zielfunktion wird durch die Teilfunktion Kritiker bereitgestellt. Die Beschreibung des Entwurfs der Teilfunktionen Kritiker und der Teilfunktion Optimierungsverfahren erfolgt in den anschließenden Unterkapiteln.

5.5.1 Entwurf des Kritikers

Der Entwurf der Teilfunktion Kritiker erfolgt entsprechend der Zielstellung der Regelungsaufgabe. Aufgabe des Kritikers ist es, die Trajektorien der Stellgrößen zu bewerten. Der Bewertungsmaßstab ist das Gütefunktional. Dieses wird aus dem Grad der Erfüllung der Regelziele, der Einhaltung der Nebenbedingungen und des Energiebedarfs des Systems abgeleitet. Basierend auf den Anforderungen des Optimierungsverfahrens kann die Zielfunktion festgelegt werden. Die Nebenbedingungen zur Erfüllung der Anforderungen an die konventionelle Regelung resultieren aus oberen bzw. unteren Grenzen der Bewertungsgrößen Innentemperatur, relative Luftfeuchte und Beschlagsfreiheit. Die Verletzung dieser Nebenbedingung kann durch einen Strafterm innerhalb der Zielfunktion berücksichtigt werden. Die Verletzung einer oberen Grenze OG einer Bewertungsgröße x im Zeitschritt n wird durch eine Strafe

$$J_{x_{OG}}(n) = (\max(x(n) - OG, 0))^2 \quad (150)$$

berücksichtigt. Die Verletzung einer unteren Grenze UG einer Bewertungsgröße x im Zeitschritt n wird durch eine Strafe

$$J_{x_{UG}}(n) = (\max(UG - x(n), 0))^2 \quad (151)$$

berücksichtigt. Die Verletzungen von oberer und unterer Grenze einer Bewertungsgröße x werden mit einem Strafparameter γ gewichtet und zu einem Strafterm

$$J_{x_G}(n) = \gamma((\max(UG - x(n), 0))^2 + (\max(x(n) - OG, 0))^2) \quad (152)$$

kombiniert. Abbildung 59 zeigt die Berücksichtigung der Grenzwertverletzungen der oberen und unteren Grenzwerte der Kabinentemperatur durch den Strafterm $J_{T_G}(n)$ bei verschiedenen Strafparametern γ .

Zur Bewertung der Beschlagsfreiheit ist die Kenntnis des Taupunktabstandes erforderlich. Da dieser nicht durch das Modell ermittelt wird, muss zunächst der Taupunkt gemäß Formel (28) aus der Innenraumtemperatur und der relativen Luftfeuchte berechnet und anschließend die Differenz zur Scheibentemperatur ermittelt werden. Der so berechnete Taupunktabstand kann durch Berücksichtigung der Untergrenze des Taupunktabstandes bewertet werden. Die Formulierung der Strafterme zur Bewertung der Grenzwertverletzungen der relativen Luftfeuchte und des Taupunktabstandes erfolgt

analog zu (153). Da die Grenzwertverletzungen über den gesamten Prognosehorizont zu berücksichtigen sind, müssen die Strafterme entsprechend aufsummiert werden.

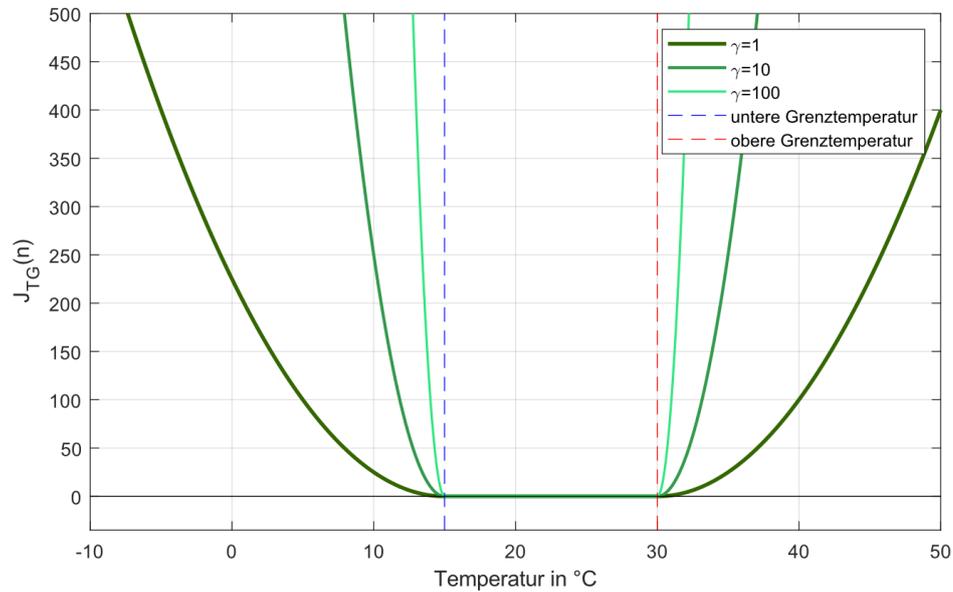


Abbildung 59 Bestrafung von Grenzwertverletzungen bei verschiedenen Strafparametern

Hieraus ergibt sich die Formulierung der Nebenbedingungen zur Berücksichtigung der Anforderungen an die konventionelle Regelung gem. Tabelle 5:

$$\begin{aligned}
 J_G &= \gamma_1 \sum_{n=1}^{n_p} ((\max(T_{UG} - T_i(n), 0))^2 + (\max(T_i(n) - T_{OG}, 0))^2) \\
 &+ \gamma_2 \sum_{n=1}^{n_p} (\max(\varphi_i(n) - \varphi_{OG}, 0))^2 \\
 &+ \gamma_3 \sum_{n=1}^{n_p} (\tau_{Abstand_{UG}} - \max(\tau_{Abstand}(n), 0))^2.
 \end{aligned} \tag{153}$$

Die Begrenzung E_G des zur Verfügung stehenden Energiebudgets zur Klimatisierung stellt eine weitere Nebenbedingung dar und muss daher ebenfalls mit

$$J_{E_G} = \gamma_4 \left(\max \left(\left(\frac{1800}{n_p^2} \sum_{n=1}^{n_p} P_v(n) + P_{PTC}(n) \right) - E_G \right), 0 \right)^2 \tag{154}$$

berücksichtigt werden. Durch Kombination der Zielfunktion der Regelziele (149) sowie den aus den Nebenbedingungen abgeleiteten Straftermen (153) und (154) ergibt sich das Gütefunktional des Kritikers:

$$J = J_R + J_G + J_{E_G}. \tag{155}$$

Für das so gebildete Gütefunktional wurden initial die Gewichtungparameter μ_1 und μ_2 mit 1, die Strafparameter γ_1 bis γ_3 mit 100 und der Strafparameter γ_4 mit 1000 belegt. Da das Prozessmodell und das Gütefunktional im ersten Entwurf vorliegen, kann der Entwurf des Optimierungsverfahrens erfolgen.

5.5.2 Entwurf der Optimierungssteuerung

Aufgabe der Optimierungssteuerung ist es, optimierte Trajektorien der beeinflussbaren Eingangsgrößen und damit der Stellgrößen zu ermitteln. Hierbei müssen die prognostizierten Trajektorien der nicht beeinflussbaren Eingangsgrößen des Prozessmodells berücksichtigt werden. Das Optimierungsproblem besteht damit im Auffinden der Trajektorien der Stellgrößen, die den Wert des Gütefunktionals minimieren.

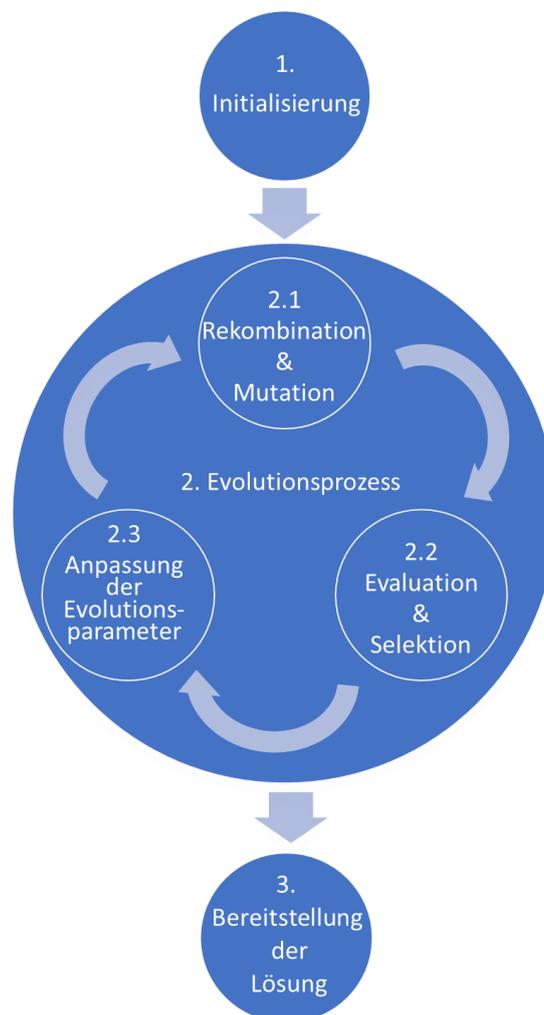


Abbildung 60 Ablauf der Optimierungssteuerung

Zur Durchführung der Optimierung wird, wie eingehend erläutert, ein Verfahren auf Basis evolutionärer Algorithmen entwickelt. Das Verfahren orientiert sich dabei am in Abbildung 58 dargestellten Prinzip, basiert aber im Wesentlichen auf sich abwechselnden Mutations- und Selektionsschritten sowie einer ständigen Anpassung der Evolutionsparameter. Die Grundidee dabei ist, ausgehend von einer Startlösung, viele Variationen dieser Startlösung zu erzeugen, die beste Variation auszuwählen und basierend auf dieser besten Lösung, wieder Variationen zu erzeugen. Dieses Wechselspiel zwischen Mutation, Selektion und Anpassung der Evolutionsparameter wird so lange wiederholt bis ein

Abbruchkriterium erreicht wird. Abbildung 60 zeigt den Ablauf des Verfahrens, welcher in den folgenden Unterkapiteln erläutert wird.

5.5.2.1 *Initialisierung*

Im ersten Schritt erfolgt die Initialisierung. Hierbei wird zunächst eine Startlösung in Form jeweils einer Trajektorie pro Stellgröße generiert. Für diese Startlösung werden die Trajektorien der Stellsignale konstant auf null gesetzt. Im Rahmen der im Schritt 2.2 (vgl. Abbildung 60) durchzuführenden Prozessprognose sind neben den Stellgrößen die nicht beeinflussbaren Eingangsgrößen erforderlich. Diese Trajektorien stehen mit dem vom Prädiktor bereitgestellten Prognoseinput zur Verfügung, können demnach über eine Schnittstelle empfangen und für den Schritt 2.2 bereitgestellt werden. Neben den Trajektorien müssen weiterhin sämtliche Parameter des Evolutionsprozesses initialisiert werden. Die Beschreibung und Festlegung der Parameter erfolgt im Rahmen der Beschreibung der Anpassung der Evolutionsparameter im Schritt 2.3 in der folgenden Erläuterung des Evolutionsprozesses.

5.5.2.2 *Evolutionsprozess*

Innerhalb des Evolutionsprozesses erfolgt die Suche der optimalen Lösung für die Trajektorien der Stellgrößen. Die Suche erfolgt ausgehend von einer Startpopulation aus einzelnen Lösungen. Diese Startpopulation bildet die Startgeneration. Durch den Evolutionsprozess erfolgt eine generationsweise Weiterentwicklung der jeweiligen Population. Dieser Prozess wird iterativ wiederholt, so dass bis zum Abbruch des Verfahrens aus jeder Generation eine verbesserte Nachfolgegeneration erzeugt wird. Die Anzahl der Wiederholungen wird durch den Evolutionsparameter Generationsanzahl bestimmt. Zu Beginn jedes Zyklus des Evolutionsprozesses erfolgt die Bildung der neuen Generation innerhalb des Schrittes 2.1 (vgl. Abbildung 60) durch Rekombination und Mutation.

5.5.2.2.1 *Rekombination und Mutation*

Die Rekombination erfolgt durch einfache Vervielfältigung der Startlösung bzw. der besten Lösung der Vorgängergeneration. Die Größe der so gebildeten Population entspricht der Anzahl der Kopien dieser Lösung und wird durch den Parameter Populationsanzahl festgelegt. Diese Population wird anschließend durch individuelle Mutationen verändert. Der Suchoperator und Kernstück des Optimierungsverfahrens ist demnach der Mutationsprozess, welcher im Folgenden erläutert werden soll.

In Analogie zur Biologie wird bei evolutionären Algorithmen zur Darstellung der Lösungen zwischen Phänotyp und Genotyp unterschieden. Der Phänotyp entspricht der Darstellung der Lösung im Problemraum, der Genotyp der Darstellung der Lösung im Suchraum. Die Darstellung im Problemraum ist die konkrete Lösung für die Stellgrößenfolge. Die Darstellung im Suchraum ist die codierte Lösung, auf der die Suche und damit die Mutation erfolgt. Die Trajektorien der Stellgrößen liegen in Form einer Folge diskreter Einzelwerte vor. Erfolgt eine Mutation durch die Veränderung eines Einzelwertes, sind aufgrund der Größe des Problemraums unhandhabbar viele Mutationen erforderlich, um eine gute Lösung zu finden. Erfolgt die Mutation durch viele unregelmäßige Veränderungen von Einzelwerten, verteilt über die vollständige Trajektorie, entstehen viele unregelmäßig verteilte Sprünge, was aus regelungstechnischer Sicht ungünstig ist. Günstig ist es daher, durch eine Mutation eine Veränderung in der Trajektorie zu bewirken, die sich auf ein ganzes Teilstück der Trajektorie auswirkt und viele unregelmäßige Sprünge vermeidet. Die Idee zur Generierung der Mutation ist es, eine Auswölbung zu erzeugen und die Trajektorie mit dieser zu beaufschlagen. Die Auswölbung wird dabei durch den Ort ihres Auftretens, die Breite und die Höhe charakterisiert.

Der Ort des Auftretens wird im Folgenden als Mutationsstelle, die Breite als Mutationsbreite und die Höhe als Mutationshöhe bezeichnet. Das Mutationsverfahren erfolgt in 4 Schritten:

- Schritt 1: Festlegung von Mutationsort und Ausmaß
- Schritt 2: Generierung der Auswölbung
- Schritt 3: Kombination von Trajektorie und Auswölbung
- Schritt 4: Glättung des Signals

Abbildung 61 veranschaulicht den Ablauf des Verfahrens in den vier Schritten graphisch. Im ersten Schritt erfolgt die pseudozufallsbasierte Festlegung von Mutationsstelle, -höhe und -breite. Hiernach erfolgt im zweiten Schritt die Generierung der Auswölbung. Hierzu wird eine quadratische Funktion mit dem Scheitelpunkt an der Mutationsstelle sowie Nullstellen an den Rändern der Mutation entsprechend der Mutationsbreite generiert. Negative Werte der Funktion werden dabei zu Null gesetzt. Anschließend wird das Signal auf die Mutationshöhe normiert und ganzzahlig um eins erhöht. Im dritten Schritt erfolgt die Kombination von Trajektorie und Auswölbung durch eine punktweise Multiplikation der Einzelwerte von Trajektorie und Auswölbung. Das resultierende Signal wird im vierten Schritt durch eine Faltungsoperation mit einem tanh-Kern geglättet. Die Breite des Faltungskerns (Faltungsfenster) wird dabei durch einen Parameter festgelegt.

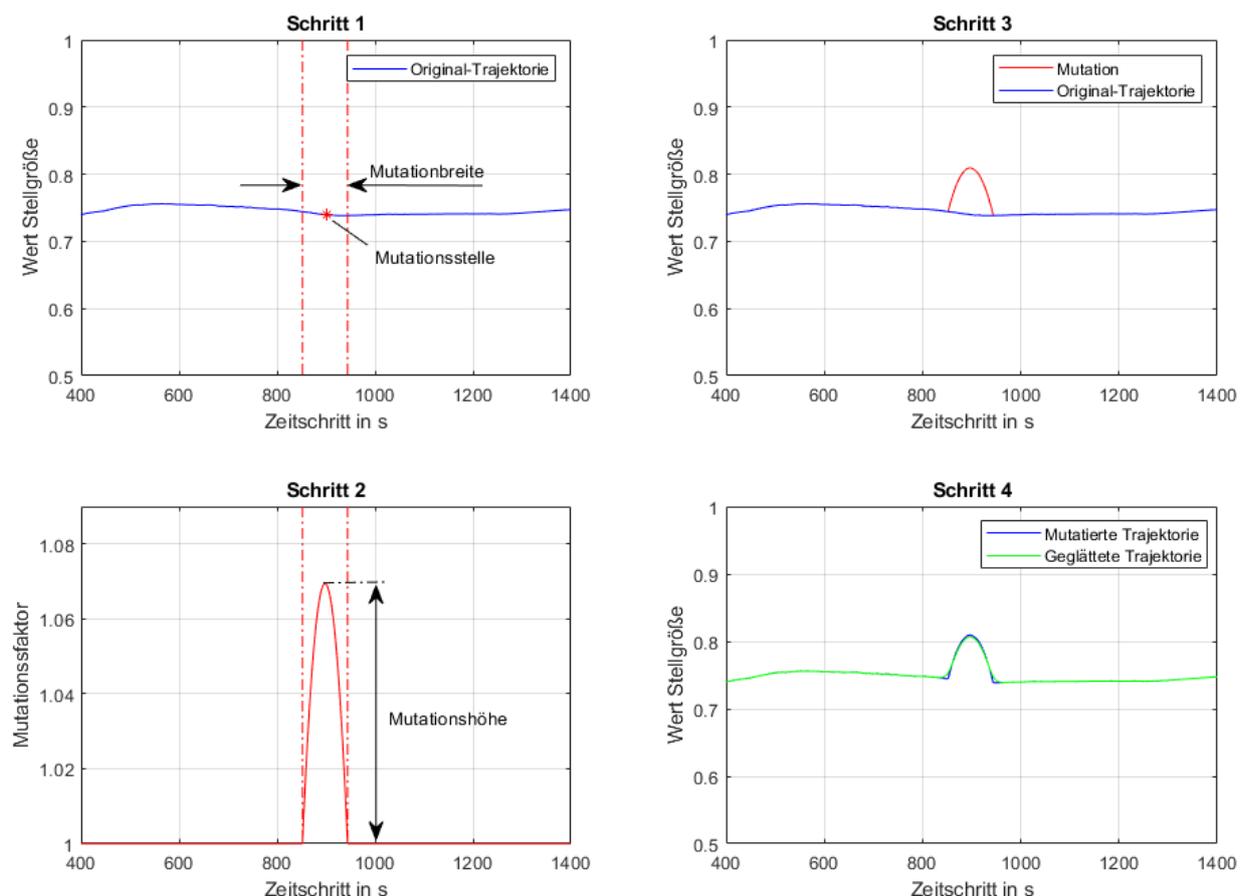


Abbildung 61 Ablauf des Mutationsverfahrens

Die Problemrepräsentation²¹ der Stellgrößen erfolgt durch Diskretisierung jeweils kontinuierlicher Funktionen im Suchraum \mathbb{R}^{n_p} in den Grenzen 0 und 1. Im Fall der Temperaturklappenstellung erfolgt eine direkte Repräsentation. Das bedeutet, der Suchraum entspricht dem Problemraum. Hierdurch müssen Darstellung und Auflösung des Signals der Trajektorie nicht verändert werden. Der Problemraum des Zustands des ACCs ist allerdings, im Gegensatz zum Suchraum, nicht reell, sondern binär (ein/aus). Daher muss das durch die Mutation gewonnene reellwertige Signal mit den Grenzen 0 und 1 in ein binärwertiges Signal überführt werden. Hierfür wird eine Pulsweitenmodulation (PWM) durchgeführt. Abbildung 62 zeigt die Darstellung des Signals nach der Mutation im Suchraum (grüne Linie) und nach der anschließenden Transformation durch das PWM-Verfahren im Problemraum.

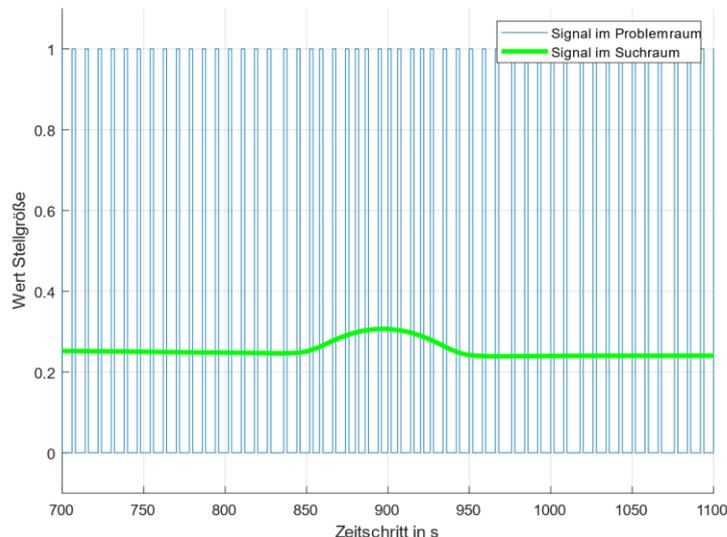


Abbildung 62 Darstellung der ACC-Trajektorie im Problem- und Suchraum

Für jedes Individuum der Population erfolgt eine individuelle Mutation, deren Auswirkung durch die pseudozufallsbasierten Parameter Mutationsstelle, Mutationsbreite und Mutationshöhe sowie dem Parameter Faltungsfenster bestimmt wird. Auf den Mutationsprozess erfolgt in jeder Generation der Evaluations- und Selektionsprozess.

5.5.2.2 Evaluation und Selektion

In diesem Prozessschritt wird jede individuelle Lösung der Population bewertet und anschließend die beste Lösung ausgewählt. Zur Bewertung der individuellen Lösungen werden die so ermittelten Stellgrößen mit den durch die Teilfunktion Prädiktor bereitgestellten Trajektorien der nicht beeinflussbaren Eingangsgrößen des Prozessmodells kombiniert. Anschließend erfolgt die Prädiktion der Zustands- und Regelgrößen durch das LSTM-Netz per Aufruf der Teilfunktion Prozessmodell. Die Prognose für sämtliche Individuen der Population erfolgt dabei simultan durch eine einzige Prädiktion, da das LSTM-Netz die aggregierten Eingangsgrößen im Batchverfahren durchführt. Das Ergebnis dieser Prognose wird anschließend durch Aufruf des Kritikers bewertet, so dass eine skalare Bewertung für jede Lösung vorliegt. Aufgrund dieser Bewertung kann die beste Lösung ausgewählt und zur Bildung einer neuen Generation im nächsten Zyklus bereitgestellt werden. Die Bewertung der Lösungen erfolgt auf Basis der Darstellung im Problemraum, die Bereitstellung der besten Lösung für den nächsten Zyklus erfolgt durch Darstellung im Suchraum.

²¹ Diese wird im Zusammenhang mit evolutionären Algorithmen z.T. auch als genetische Repräsentation bezeichnet.

5.5.2.2.3 Anpassung der Evolutionsparameter

Um ein gutes Konvergenzverhalten evolutionärer Algorithmen zu erzielen, ist es hilfreich den Evolutionsprozess kontinuierlich an die aktuelle Situation im Optimierungsprozess anzupassen (vgl. [132] S.108 ff.). Dies kann durch eine Anpassung der Evolutionsparameter während des Optimierungsprozesses erfolgen. Die Entwicklung einer Anpassungsstrategie basiert auf den im Folgenden erläuterten Überlegungen.

Das zeitliche Verhalten geregelter Systeme lässt sich durch eine Aufteilung in transiente und stationäre Phasen beschreiben. In den transienten Phasen, welche auch als Einschwingvorgänge bezeichnet werden, werden die Regelgrößen durch den Regelungsprozess auf das Niveau der entsprechenden Führungsgrößen gebracht. Der Systemzustand wird quasi auf den Zielzustand „gehoben“. In den stationären Phasen befinden sich die Regelgrößen in einem stabilen eingeschwungenen Zustand nah an den Führungsgrößen. Hierbei werden durch den Regelungsprozess im Wesentlichen die Einflüsse der Störgrößen ausgeglichen. Ziel ist es nun, wie auch in der konventionellen Regelung, die stationäre Phase so schnell wie möglich zu erreichen und dann die Wirkung der Störgrößen zu kompensieren. Hierfür muss die dementsprechende Trajektorie gefunden werden.

Die Strategie zum Auffinden einer solchen Trajektorie ist es nun, zu Beginn des Optimierungsprozesses das optimale Niveau der Stellgrößen im stationären Zustand mit wenigen Optimierungsschritten zu erreichen. Im späteren Verlauf der Optimierung sind dann die Stellgrößen, im Besonderen im Bereich der transienten Phase, zu verfeinern. Dazu sind in der Anfangsphase Mutationen mit großer Mutationsbreite und in späteren Phasen Mutationen mit kleiner Mutationsbreite erforderlich. Die Anpassung der Mutationsbreite wird dementsprechend in Abhängigkeit des Konvergenzverhaltens des Optimierungsprozesses durchgeführt. Hierzu wird die Verbesserung der Güte im Vergleich zur Vorgängergeneration bewertet. Die Mutationsbreite wird pseudozufallsbasiert unter Festlegung eines variablen Maximalwertes der Mutationsbreite generiert. Ausgehend von einer initialen maximalen Mutationsbreite wird in Abhängigkeit der Verbesserung der Güte der besten Lösung der jeweiligen Generation die maximale Mutationsbreite erniedrigt oder erhöht. Der initiale Maximalwert der Mutationsbreite wird anhand des Prognosehorizont n_p bestimmt. Unterschreitet die Verbesserung einen Grenzwert, so wird die maximale Mutationsbreite erniedrigt, überschreitet sie diesen, wird sie erhöht. Die Veränderung der maximal möglichen Mutationsbreite erfolgt durch Multiplikation bzw. Division mit einem Abnahmefaktor.

Neben der Mutationsbreite sind weitere Parameter des Evolutionsprozesses festzulegen. Für jedes Individuum der Population ist jeweils eine individuelle Mutationsstelle und eine zugehörige Mutationshöhe zu bestimmen.

Evolutionsparameter	Initialisierungswert
Initiale maximale Mutationsbreite	$n_p \cdot 2000$
Abnahmefaktor	1,07
Grenzwert Verbesserung	0,01
Maximale Mutationshöhe	0,2
Population	100
Generation	200
Fensterbreite des tanh-Faltungskerns	21

Tabella 19 Festgelegte Evolutionsparameter

Die Mutationsstelle wird pseudozufallsbasiert auf dem Intervall vom Prognosestartzeitpunkt bis zum Prognosehorizont n_p bestimmt. Die Mutationshöhe wird ebenfalls pseudozufallsbasiert und durch einen Maximalwert begrenzt bestimmt. Des Weiteren ist als Abbruchkriterium des Optimierungsprozesses eine maximale Anzahl der zu durchlaufenden Generationen, die Populationsanzahl und die Fensterbreite des Faltungsfensters festzulegen. Diese Parameter werden einmalig zur Initialisierung statisch festgelegt und während des Optimierungsprozesses nicht weiter verändert. Die Ermittlung der Parameter erfolgte empirisch. Anhang A.11 zeigt die Ergebnisse des hierfür durchgeführten Versuchs im Rastersuchverfahren zur Bestimmung einer geeigneten Kombination von Populations- und Generationsanzahl sowie Fensterbreite. Tabelle 19 zeigt die Zusammenfassung der ermittelten Evaluationsparameter.

Nach der Festlegung sämtlicher Parameter kann das Verfahren ausgeführt werden. Abbildung 63 zeigt exemplarisch die Evolution der so gewonnenen Lösungen für die Stellgröße Temperaturklappe innerhalb verschiedener Generationswechsel. Die blaue Linie zeigt im Vergleich den Verlauf der Stellgröße durch eine konventionelle Regelung bei gleichen Rahmenbedingungen.

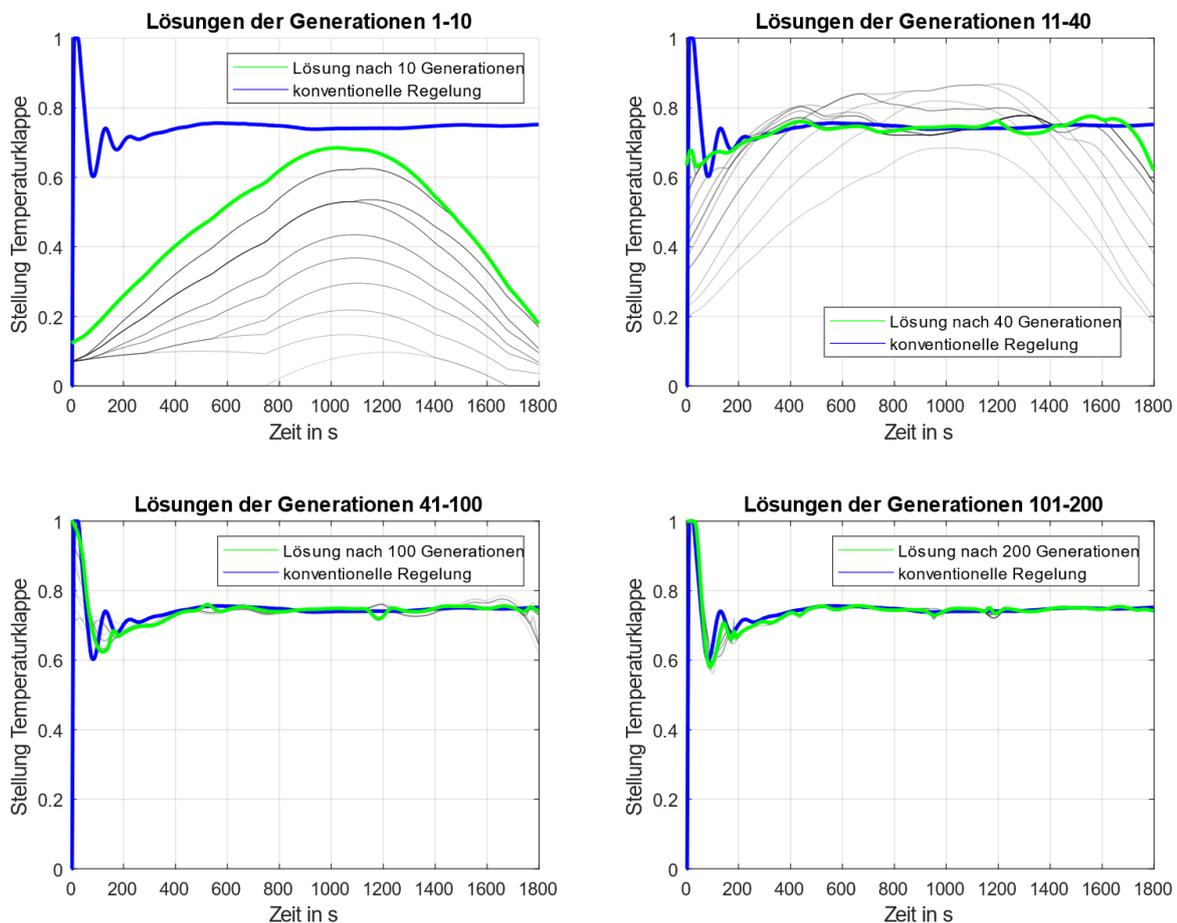


Abbildung 63 Veränderung der Lösung im Optimierungsprozess

5.5.2.3 Bereitstellung der Lösung

Nach Abbruch des Optimierungsverfahrens kann die resultierende Lösung in Form einer Stellfolge für jede Störgröße bereitgestellt werden. Hierbei ist eine Darstellung der Stellfolgen im Problemraum erforderlich, so dass die einzelnen Werte der Stellfolgen direkt als Führungsgrößen der nachfolgenden weiteren Teilregelungen verwendet werden können.

5.6 Systemsynthese

Nach dem Entwurf von Lösungsansätzen für die einzelnen Teilfunktionen erfolgt ein weiterer Synthese- und Analyseschritt zur Komposition des Lösungsansatzes für die Steuerung des Systems. Hierfür wurde der Lösungsansatz zur Teilfunktion Modellprädiktiver Optimierer mit den Komponenten Optimierungssteuerung, Prozessmodell und Kritiker prototypisch in Matlab gemäß dem Vorgehen der Kapitel 5.2.1, 5.5.1 und 5.5.2 implementiert. Im Prozessmodell wird das initial trainierte LSTM-Netz verwendet. Zur Analyse der Umsetzung wurden die Eingänge des Systems durch die Umgebungsbedingungen der im Rahmen der Situationsanalyse erstellten Versuchsszenarien stimuliert und durch Ausführung der Teilfunktion Modellprädiktiver Optimierer jeweils die optimierte Trajektorie der Stellgröße ermittelt. Mit den so gewonnenen Trajektorien wurde anschließend für die jeweiligen Umgebungsbedingungen eine Simulation am in Kapitel 5.2.1.3 beschriebenen Matlab-Simulink-Modell mit der FMU des Modelica-Gesamtmodells des Heizungs-, Lüftungs- und Klimaanlage systems und der Fahrzeugkabine durchgeführt. Abbildung 64 zeigt beispielhaft am Versuchsszenario Nr. 193 den optimierten Verlauf der Temperaturklappenstellung sowie der resultierenden Kabinentemperatur.

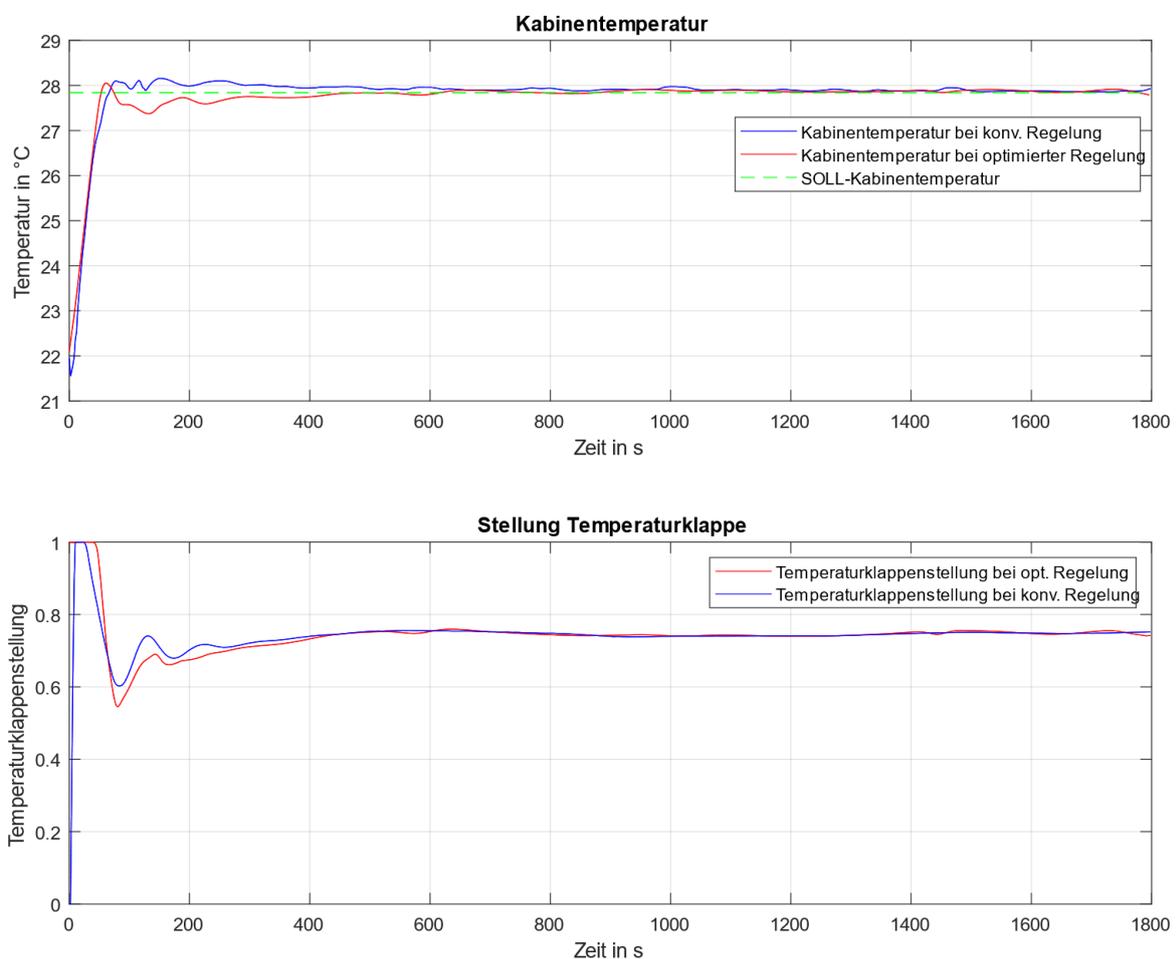


Abbildung 64 Temperatur- und Stellgrößenverläufe im Versuchsszenario 193

Wie in der Abbildung erkenntlich, befindet sich die Trajektorie der optimierten Temperaturklappenstellung nah an der der konventionellen Regelung. Im Gegensatz zur konventionellen Regelung startet die Trajektorie der optimierten Temperaturklappenstellung direkt bei der maximalen Temperaturklappenstellung. Hiernach weist sie ein ähnliches Einschwingverhalten wie die der konventionellen Regelung auf. Die Regelgröße erreicht die Solltemperatur etwas schneller, überschwingt diese kurz,

unterschwingt sie dann aber, bis sie den stationären Zustand erreicht. Im stationären Zustand sind die Trajektorien nahezu identisch, wobei die optimierte Trajektorie die Störgrößen etwas besser kompensiert. Hierbei werden zwei Verbesserungspotentiale deutlich. Zum einen muss ein Überschreiten der SOLL-Kabinentemperatur generell vermieden werden, da hierdurch ein unnötiger Energiebedarf verursacht wird. Zum anderen muss das Einschwingverhalten gedämpft werden, um eine höhere Regelgüte im Sinne der Einhaltung der Metrik 1 zu erzielen.

Diese Verbesserung kann durch Anpassung des Gütefunktional innerhalb der Teilfunktion Kritiker erfolgen. Zur stärkeren Dämpfung des Einschwingverhaltens wird der Stellaufwand der Stellgrößen durch Erhöhung des Gewichtsparmeters μ_2 um den Faktor 10 stärker bestraft (vgl. Formel (149)). Zur Vermeidung einer Überschreitung der SOLL-Temperatur durch Beheizen der Kabinenluft wird eine zusätzlicher Strafterm

$$J_{V1} = \gamma_5 \sum_{n=1}^{n_p} (tk_n * \max(T_{Ist}(n) - T_{Soll}(n), 0))^2 \tag{156}$$

für das Gütefunktional erstellt. Analog hierzu wird zur Vermeidung des Unterschreitens der Soll-Temperatur durch Kühlen der Kabinenluft ein weiterer Strafterm für das Gütefunktional erstellt:

$$J_{V2} = \gamma_6 \sum_{n=1}^{n_p} (ACC_n * \max(T_{Soll}(n) - T_{Ist}(n), 0))^2. \tag{157}$$

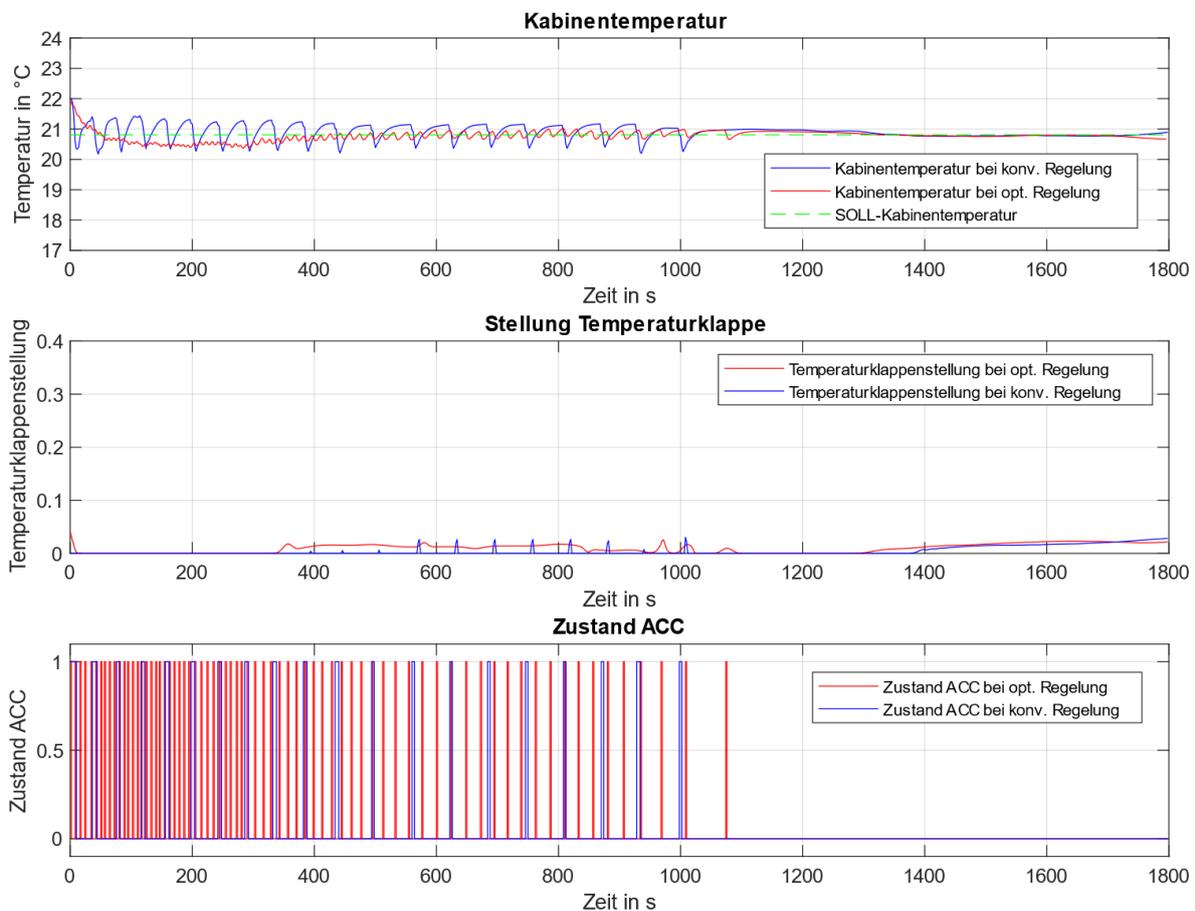


Abbildung 65 Temperatur- und Stellgrößenverläufe im Versuchsszenario 237

Weiteres Verbesserungspotential wird durch die Betrachtung der Ergebnisse der Optimierung bei moderaten Umgebungstemperaturen ersichtlich. Abbildung 65 zeigt hierfür, anhand des Versuchsszenarios Nr. 237, den optimierten Verlauf der Temperaturklappenstellung und des ACC-Zustands sowie der resultierenden Kabinentemperatur. Wie auch im Versuchsszenario Nr. 193 befinden sich die Trajektorien der optimierten Temperaturklappenstellung nah an der konventionellen Regelung. Der Verlauf der Kabinentemperatur durch Einstellung der optimierten Stellgrößen zeigt die oben erwähnte Problematik durch leichtes Überschwingen. Die Kabinentemperatur fällt zunächst unter die Soll-Temperatur ab und nähert sich dieser anschließend wieder an. Wie im Verlauf der Temperaturklappenstellung ersichtlich, wird dies zum Teil durch das Öffnen der Temperaturklappe bewirkt. Die zuvor zu viel zugeführte Kühlleistung wird demnach durch zusätzliche Heizleistung kompensiert. Hieraus resultiert ein erhöhter Energiebedarf. Um dieses unerwünschte Verhalten zu vermeiden, wird eine weitere Anpassung innerhalb der Teilfunktion Kritiker vorgenommen. Dazu wird ein zusätzlicher Strafterm

$$J_{V3} = \gamma_7 \sum_{n=1}^{n_p} ACC_n * tk_n \quad (158)$$

zur Bestrafung von gleichzeitigem Heizen und Kühlen eingefügt. Durch die Zusammenführung von (156)-(158) mit (155) ergibt sich das Gütefunktional des Kritikers:

$$J = J_R + J_G + J_{E_G} + J_{V1} + J_{V2} + J_{V3}. \quad (159)$$

Nach Durchführung der Umsetzung der erforderlichen Anpassungen dieses Syntheseschrittes folgt im Mikrozyklus die Analyse und Bewertung des Lösungsansatzes. Hiernach erfolgen die Entscheidung sowie die Festlegung des Weiteren Vorgehens. Die Beschreibung der Durchführung dieser Schritte erfolgt im folgenden Kapitel 6.

6 Analyse und Bewertung

Die Analyse zum Abschluss des ersten Durchlaufs des Mikrozykluses erfolgt in zwei Schritten. Zunächst wird, analog zu der in Kapitel 4.2.1 durchgeführten Situationsanalyse, eine Untersuchung anhand der bereits erstellten Testszenarien durchgeführt. Hierbei wird zum einen das Verhalten der Modellprädiktiven Steuerung bei dynamischen Schwankungen der Umgebungsgrößen überprüft. Hierfür werden die Versuchsszenarien der zweiten Versuchsreihe (Versuchsszenarien Nr. 193-384) verwendet. Des Weiteren werden die Auswirkungen des Verhaltens der Optimierungssteuerung bei begrenztem Energiebudget untersucht. Hierfür werden die Umgebungsbedingungen der ersten Versuchsreihe übernommen und ein maximales Energiebudget von 1,1 kWh festgelegt.

Im zweiten Schritt der Analyse wird die Lernfähigkeit des Systems überprüft. Die Analyse erfolgt wieder anhand von Simulationen am Matlab-Simulink-Modell mit der FMU des Modelica-Gesamtmodells. Die Versuchsszenarien werden hierbei aus durch 30 Fahrzeugmessungen gewonnenen Messwerten konstruiert. Die Fahrzeugmessungen wurden dabei auf der Strecke Goslar-Clausthal durchgeführt. Abbildung 66 zeigt den Ablauf des zweiten Analyseschrittes. Zunächst wird eine Optimierung auf Basis des initial trainierten LSTM-Netzes durchgeführt. Das Optimierungsergebnis wird eingesteuert und anschließend bewertet. Hiernach erfolgt eine Anpassung des Prozessmodells durch Nachtrainieren des LSTM-Netzes. Zum Trainieren des Netzes werden ebenfalls Versuchsszenarien aus durch Fahrzeugmessungen gewonnenen Messwerten konstruiert. Hierfür wurden weitere 30 Fahrzeugmessungen auf der Strecke Goslar-Clausthal verwendet. Mit diesem nachtrainierten Modell wird dann die Versuchsreihe wiederholt. Der Optimierungsprozess wird erneut durchgeführt und abschließend bewertet.

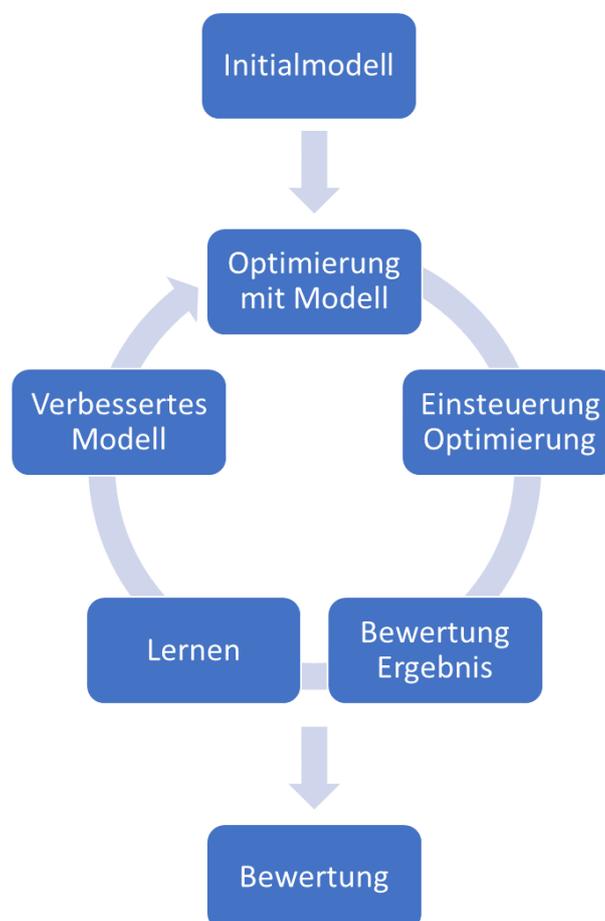


Abbildung 66 Ablauf des zweiten Analyseschrittes

6.1 Experimentelle Untersuchung

Im ersten Schritt der Analyse wurde, analog zum in Kapitel 4.2.1 beschriebenen Vorgehen, die Einhaltung der Anforderungen an die konventionelle Regelung überprüft sowie die Energieeffizienz bewertet. Zunächst wurde der prototypisch umgesetzte Lösungsansatz durch die Durchführung der Versuchsreihe II überprüft. Anhang A.12 zeigt zusammenfassend die Auswertung der Metriken zur Bewertung der erreichten Regelgüte und Energieeffizienz. Diese Ergebnisse werden im Folgenden diskutiert.

6.1.1 Erreichung der Optimierungsziele

Der Mittelwert der Bewertung der Regelgüte nach Metrik Nr. 1 über die 192 Versuchsszenarien der Versuchsreihe II ergibt 0,543 K. Im Vergleich zur konventionellen Regelung (0,678 K) bedeutet dies eine Verbesserung. Ähnlich wie bei der konventionellen Regelung traten Verletzungen des Zielwertes von maximal einem Kelvin Differenz zur Solltemperatur bei hohen Temperaturen und hohen Strahlungsin Intensitäten auf, fielen aber insgesamt im Vergleich zur konventionellen Regelung um 5 % geringer aus.

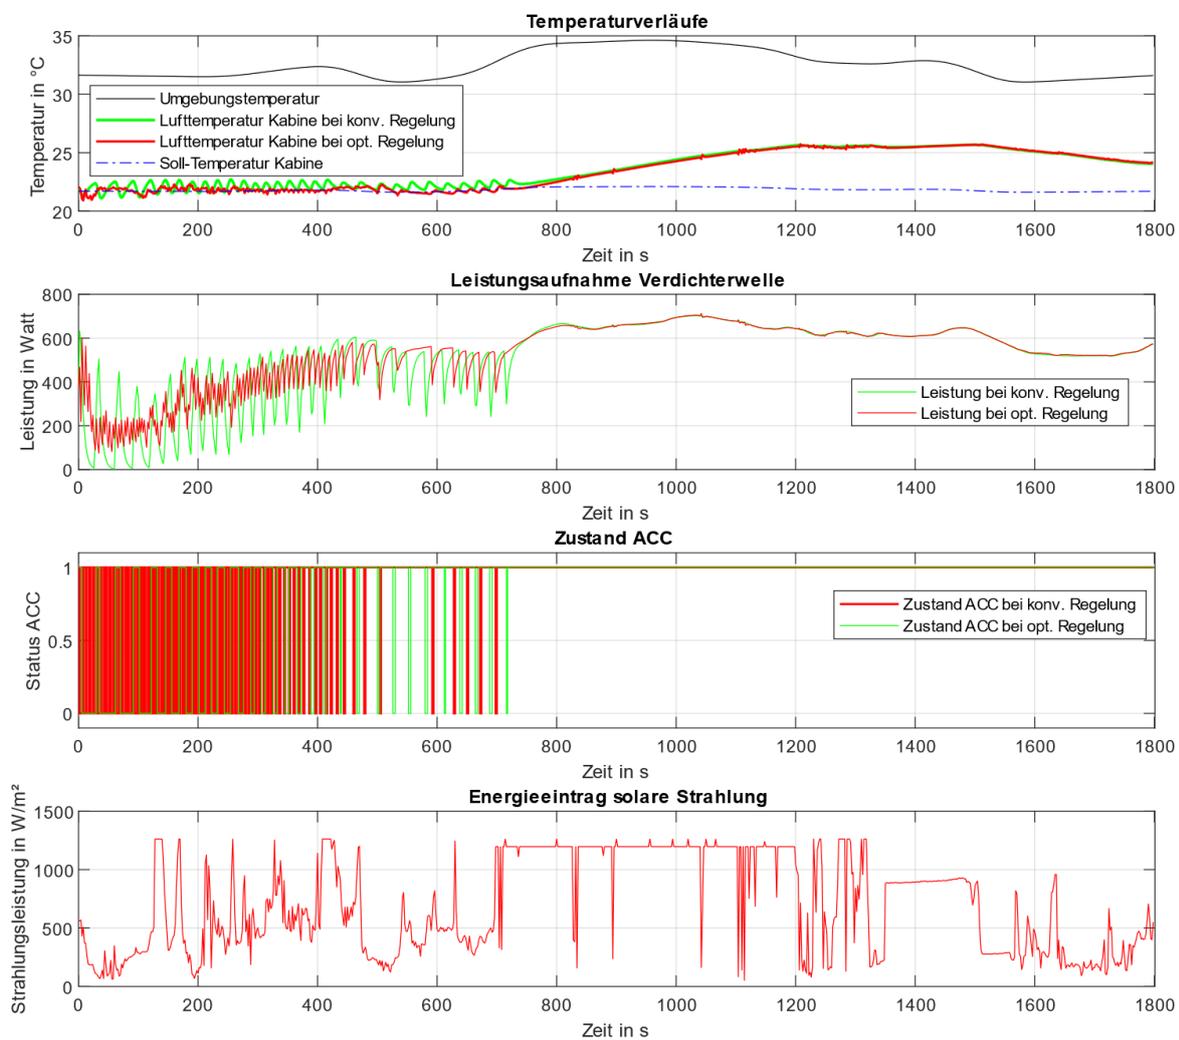


Abbildung 67 Temperatur-, Strahlungs- und Stellgrößenverläufe im Versuchsszenario Nr. 336

Abbildung 67 zeigt hierfür beispielhaft die Temperatur- und Stellgrößenverläufe bei heißen Umgebungsbedingungen und hoher solarer Strahlung am Versuchsszenario Nr. 336. Wie auf der Abbildung zu erkennen, liegt die Kabinentemperatur bei optimierter Regelung in den ersten 700 Sekunden sehr dicht am Sollwert und unterschreitet dabei die Regelabweichung der konventionellen Regelung.

Hiernach erreicht der Energieeintrag durch solare Strahlung extrem hohe Werte, die in der Folge nicht vollständig kompensiert werden können. Wie auch im Fall der konventionellen Regelung ist bei diesen Umgebungsbedingungen eine Erhöhung des Luftmassenstroms zur Zielerreichung erforderlich. Da die Stellgröße Frischluftgebläsestufe auch hier durch die Regelung nicht beeinflusst wird, kann der notwendige Luftmassenstrom nicht eingestellt werden. Im Gegensatz zur konventionellen Regelung wird der Zustand des ACC etwas früher dauerhaft angeschaltet, so dass in der Folge die Kabinentemperatur Werte leicht unten den Werten bei konventioneller Regelung liegt.

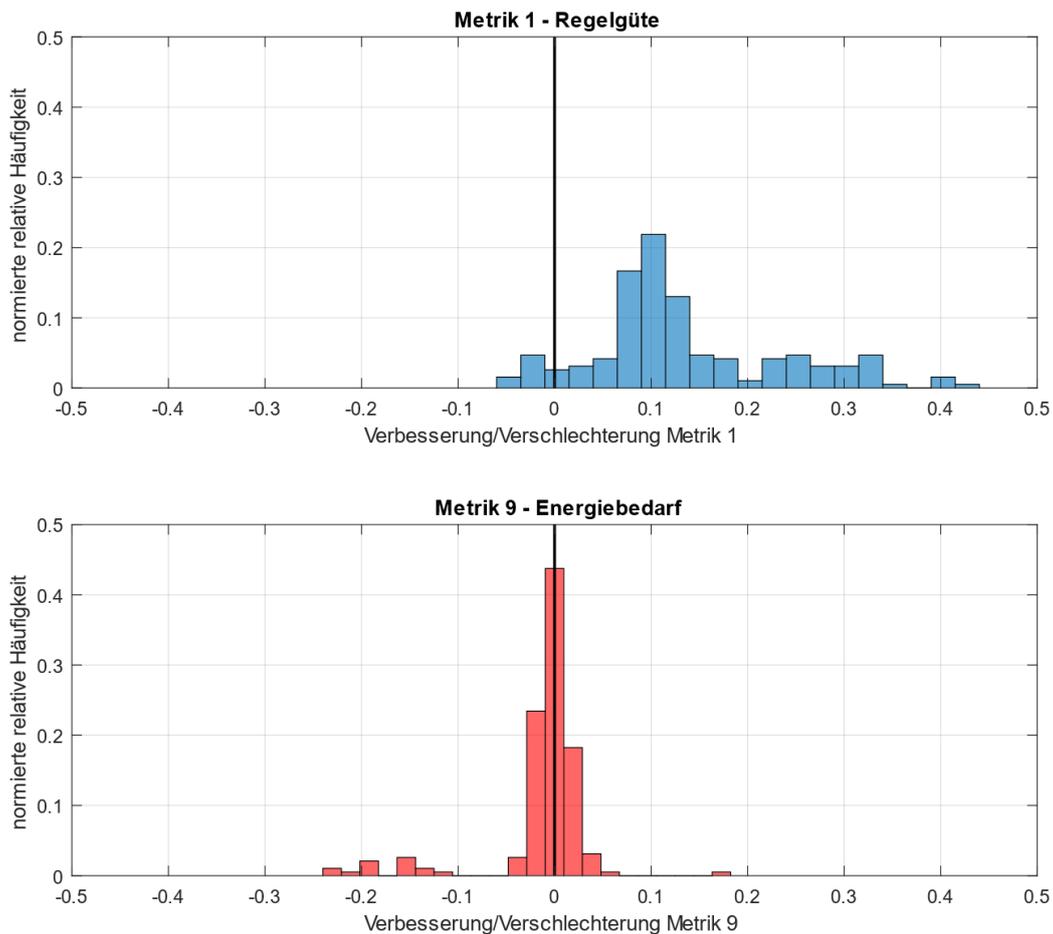


Abbildung 68 Häufigkeit der Verbesserung/Verschlechterung im Vergleich zur konv. Regelung

Der durchschnittliche Gesamtenergiebedarf aller Versuchsszenarien lag im Bereich der konventionellen Regelung. Abbildung 68 zeigt die Häufigkeit der jeweils aufgetretenen Verbesserungen bzw. Verschlechterungen der Regelgüte (Metrik 1) und des Energiebedarfs (Metrik 9). Negative Werte zeigen hierbei eine Verschlechterung der jeweiligen Metrik im Vergleich zur konventionellen Regelung an. Auffällig sind hierbei die vereinzelt auftretenden deutlichen Erhöhungen des Energiebedarfs. Diese deutlichen Erhöhungen traten ausschließlich bei Versuchsszenarien mit einer Umgebungstemperatur zwischen 20 und 25 °C auf. Die Ursache hierfür liegt in der schwächeren Generalisierungsfähigkeit des trainierten Netzes in diesem Temperaturbereich. Aufgrund von Abweichungen des prognostizierten zum tatsächlichen Prozessverhalten sind in diesen Fällen die durch die Optimierungssteuerung ermittelten Trajektorien nicht optimal.

Die Zielwerte der Metriken Nr. 2-5 wurden in allen Versuchsszenarien eingehalten und somit die geforderten Nebenbedingungen erfüllt. Unabhängig von den Umgebungsbedingungen wurde eine

Kabinentemperatur innerhalb des geforderten Temperaturfensters zwischen 15 °C und 30 °C (Metrik Nr. 2 und Nr. 3) und eine relative Luftfeuchtigkeit unter 80 % (Metrik Nr. 4) eingestellt sowie ein Taupunktabstand von mindestens 1,5 K (Metrik Nr. 5) eingehalten.

Ein Ziel des modellprädiktiven Ansatzes ist die Maximierung der Regelgüte bei paralleler Minimierung des Energiebedarfs. Abbildung 69 stellt, hinsichtlich der Erreichung dieses Zieles, die jeweilige Veränderung der Bewertung der Regelgüte (Metrik 1) und des Energiebedarfs (Metrik 9) im Vergleich zur konventionellen Regelung dar. Da sowohl eine Verbesserung der Regelgüte als auch eine Verringerung des Energiebedarfs gefordert sind, sollten sich alle Werte im oberen rechten Quadranten befinden. Dieses Ziel wurde mit dem initial trainierten Prozessmodell nicht in allen Versuchsszenarien erreicht.

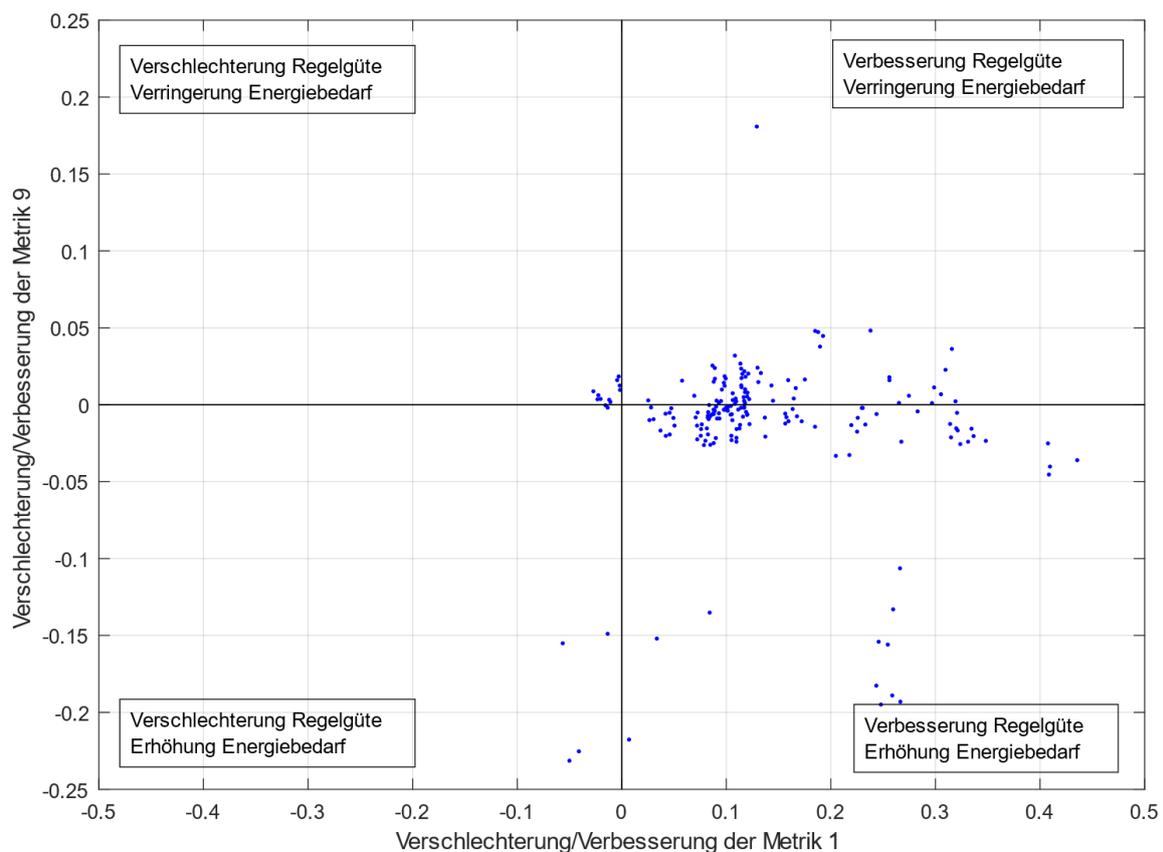


Abbildung 69 Zielerreichung mit initial trainiertem Prozessmodell

Wie in der Abbildung zu erkennen, tritt in 15 Versuchsszenarien eine Verschlechterung der Metrik 9 über den Wert von 0,1 im Vergleich zur konventionellen Regelung auf. Hierbei handelt es sich um die bereits erwähnten Versuchsszenarien mit einer Umgebungstemperatur zwischen 20 und 25 °C. Eine Verbesserung der Regelgüte bei gleichzeitiger Senkung des Energiebedarfs konnte in 33 % der Versuchsszenarien erreicht werden. Bei einem weitaus größeren Anteil von 59 % der Versuchsszenarien wurde die Regelgüte zu Lasten eines höheren Energiebedarfs erhöht. Dies wird nur zu einem geringen Anteil durch Prognosefehler des Prozessmodells verursacht. Abbildung 70 verdeutlicht diesen Sachverhalt am Beispiel des Versuchsszenarios Nr. 268. Die Trajektorie der Temperaturklappenstellung bei konventioneller Regelung startet bei der Position Null und schwingt sich dann auf den Zielwert ein. Die optimierte Trajektorie startet im Gegensatz zur konventionellen Regelung direkt auf dem Maximalwert und nähert sich dann dem stationären Zustand. Der resultierende Verlauf der Leistungsaufnahme des PTC-Heizelements ist in beiden Fällen für ca. 100 Sekunden identisch. Dies liegt darin begründet, dass

die interne Regelung des Heizkreislaufs zunächst die SOLL-Nachlaufzeittemperatur im Heizkreislaufs einstellt.

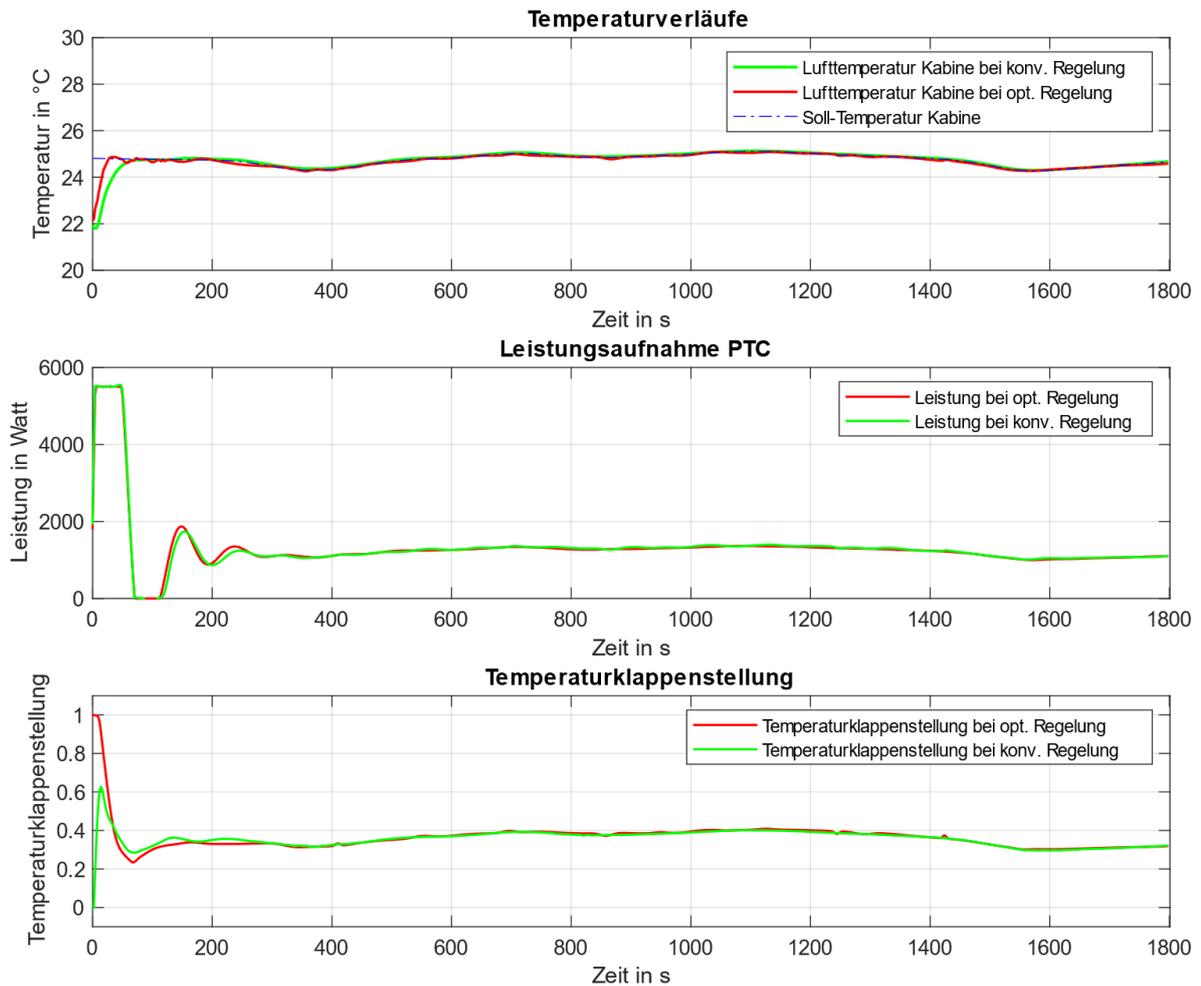


Abbildung 70 Temperatur-, Leistungs- und Stellgrößenverläufe im Versuchsszenario Nr. 268

Wegen der höheren Werte der Temperaturklappenstellung im optimierten Fall wird dem Heizkreislauf in der Anfangsphase mehr Wärme entzogen. Dies hat zur Folge, dass die Nachlaufzeittemperatur im Heizkreislaufs früher nachgeregelt werden muss, was zu einer höheren Leistungsaufnahme führt. Durch die höhere Wärmezufuhr in der Anfangsphase erreicht die Lufttemperatur der Kabine im optimierten Fall schneller den SOLL-Wert, was wiederum zu einem niedrigeren Wert der Metrik 1 im Vergleich zur konventionellen Regelung führt.

Die Ursache des höheren Energiebedarfs liegt demnach nicht im Fehlverhalten der Optimierungssteuerung, sondern in der gegenläufigen Abhängigkeit der beiden Ziele Regelgüte und Energiebedarfsoptimierung. Um eine Energiebedarfsreduzierung zu erreichen ist demnach eine Anpassung der Metrik 1, z.B. durch Einführung einer Toleranzschwelle, sowie einer Berücksichtigung dieser im Gütefunktional des Kritikers notwendig.

Das zweite Ziel des modellprädiktiven Ansatzes ist die Maximierung der Regelgüte bei begrenztem verfügbarem Energiebudget. Hierzu wurden, analog zum in Kapitel 4.2.1 beschriebenen Vorgehen, die Auswirkungen des Verhaltens der Optimierungssteuerung bei begrenztem Energiebudget untersucht. Dazu wurden die Umgebungsbedingungen der ersten Versuchsreihe übernommen. Die Analyse

erfolgte wieder anhand von Simulationen der 192 Versuchsszenarien am Matlab-Simulink-Modell mit der FMU des Modelica-Gesamtmodells. Anhang A.13 zeigt zusammenfassend die Auswertung der Metriken zur Bewertung der erreichten Regelgüte, der Grenzwertverletzungen sowie der Energieeffizienz. Die Regelgüte gemäß Metrik 1 wurde durch die modellprädiktive Optimierung über sämtliche 192 Versuchsszenarien im Durchschnitt um 8,46% verbessert. Die Verletzung der Anforderung Nr. 2 (Unterschreitung Mindesttemperatur), bewertet durch Metrik Nr. 3, wurde um 32,97 % verringert. Abbildung 71 zeigt hierfür beispielhaft die Verläufe von Kabinentemperatur, Leistungsaufnahme PTC sowie Temperaturklappenstellung im Vergleich zur konventionellen Regelung.

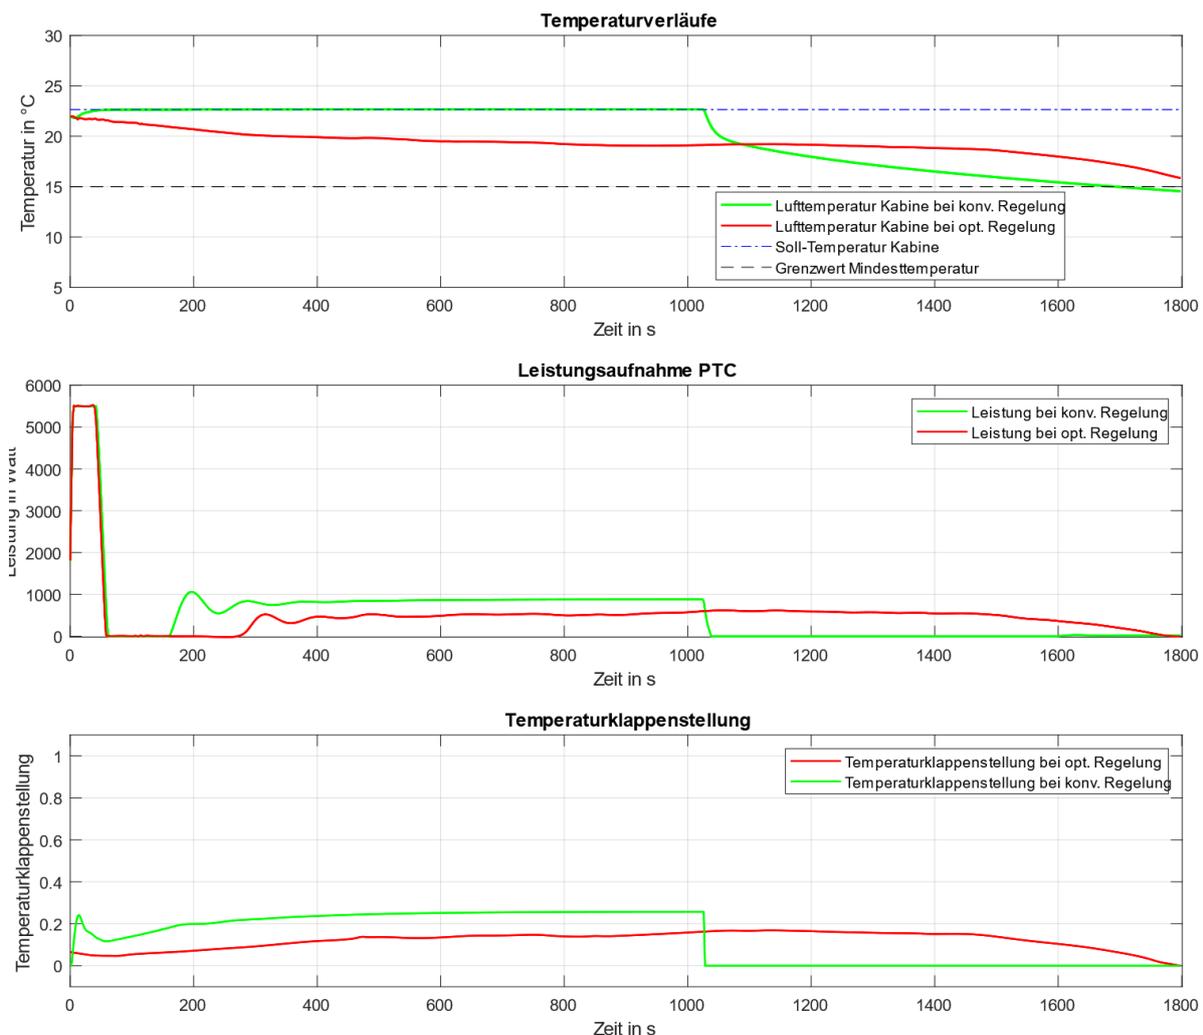


Abbildung 71 Temperatur-, Leistungs- und Stellgrößenverläufe im Versuchsszenario Nr. 426

Wie aus der Abbildung ersichtlich, werden im optimierten Fall in der Anfangsphase niedrigere Werte der Temperaturklappenstellung eingestellt. Hierdurch fällt die Kabinentemperatur auf ca. 20° C ab, bleibt dann aber relativ konstant. Im Gegensatz zur konventionellen Regelung wird die verfügbare Energie so über den vollständigen Prognosehorizont verteilt. Da die Regelgüte in sämtlichen Testszenarien die der konventionellen Regelung übersteigt, wurde das zweite Ziel des modellprädiktiven Ansatzes erreicht.

6.1.2 Lernfähigkeit des Verfahrens

Zur Überprüfung der Lernfähigkeit des Verfahrens war die Erstellung einer weiteren Versuchsreihe erforderlich. Hierfür wurden Messdaten der Umgebungsbedingungen durch 60 reale Fahrten auf der Strecke Goslar-Clausthal aufgezeichnet. Für diese Umgebungsbedingungen wurden Simulationen der konventionellen Regelung am Matlab-Simulink-Modell mit der FMU des Modelica-Gesamtmodells durchgeführt. Anschließend wurden die Simulationseingänge- und Ergebnisse, wie in den Kapiteln 5.2.1.3 und 5.3.1.1 beschrieben, zu einem Datensatz aggregiert. Dieser Datensatz wurde dann in zwei Datensätze, einen Lern- und einen Testdatensatz, aufgeteilt.

In einer ersten Versuchsreihe wurde unter Verwendung der Umgebungsbedingungen des Testdatensatzes eine Optimierung auf Basis des initial trainierten LSTM-Netztes durchgeführt. Das Optimierungsergebnis wurde anschließend in eine erneute Simulation eingesteuert und bewertet. Hiernach wurde das Prozessmodell durch Verwendung des Lerndatensatzes nachtrainiert.

In einer zweiten Versuchsreihe wurde die erste Versuchsreihe mit dem nachtrainierten Prozessmodell wiederholt, der Optimierungsprozess zu gleichen Umgebungsbedingungen des Testdatensatzes erneut durchgeführt und abschließend bewertet. Abbildung 72 zeigt die Ergebnisse bezüglich der Zielerreichung im Vergleich zur ersten Versuchsreihe.

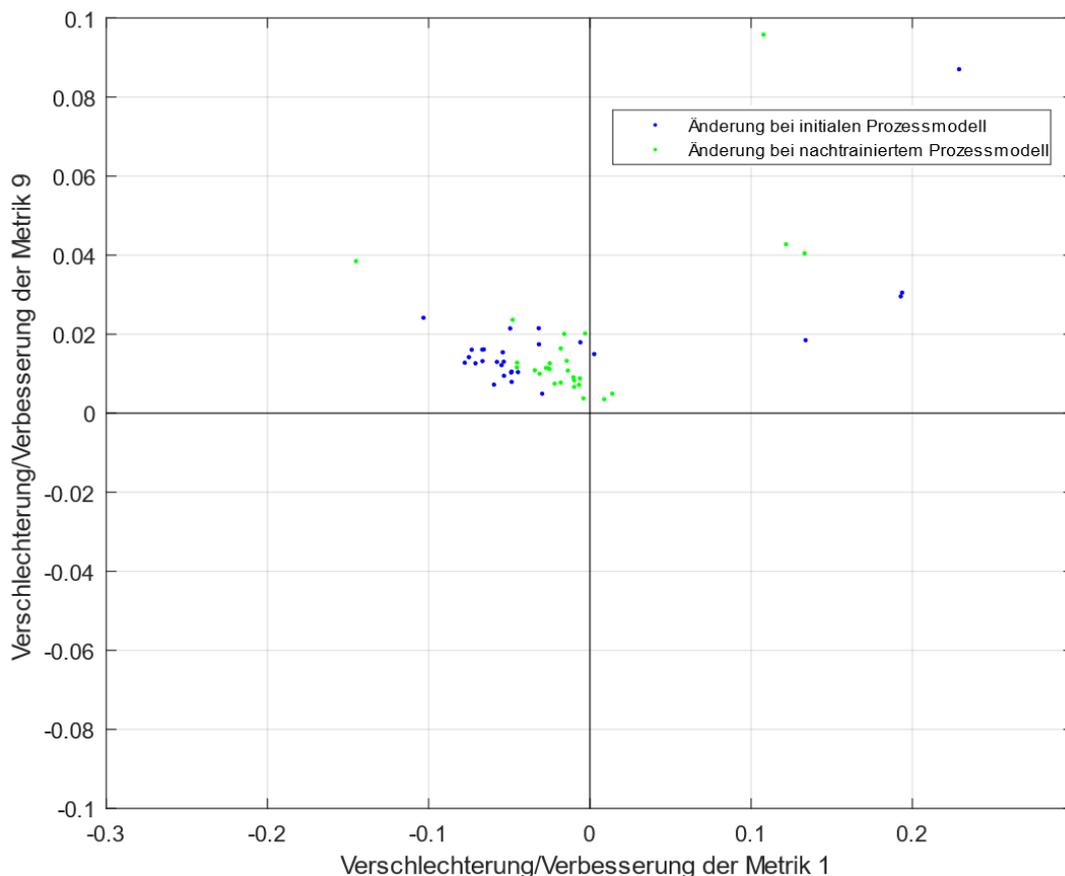


Abbildung 72 Zielerreichung mit initial trainiertem und nachtrainiertem Prozessmodell

Wie aus der Abbildung ersichtlich, wird die durchschnittliche Regelgüte (Metrik 1) durch die Optimierung mit dem nachtrainierten Modell deutlich verbessert. Die durchschnittliche Verbesserung der Metrik 9 (Energiebedarf) im Vergleich zur ersten Versuchsreihe fällt sehr gering aus, was sich mit den Erkenntnissen des Kapitels 6.1.1 deckt. Das Optimierungspotential wird hinsichtlich der formulierten

Metriken sowie des erstellten Gütefunktionalen nahezu vollständig ausgeschöpft. Insgesamt wurde im Vergleich zur konventionellen Regelung in den Testszenarien eine durchschnittliche Verringerung des Energiebedarfs um ca. 1 % erreicht.

6.2 Entscheidung

Durch den modellprädiktiven Ansatz zur Regelung des HLK-Systems kann das durch Einstellung der Regelgrößen Temperaturklappe und ACC-Zustand ausnutzbare Optimierungspotential nahezu vollständig ausgeschöpft werden. Im Fall einer begrenzten Energiemenge zur Heizung und Klimatisierung des Fahrzeugs wird durch den entworfenen Lösungsansatz eine deutlich höhere Regelgüte erzielt. Wird die Energiemenge nicht begrenzt, kann das Regelziel, bei entsprechend präziser Prognose der Zustandsgrößen, mit nahezu minimalem Energieaufwand erreicht werden. Aufgrund des Zielkonfliktes zwischen Minimierung der aufzuwendenden Energie und der Erreichung einer hohen Regelgüte ist es allerdings nicht in allen Fällen möglich, im Vergleich zur konventionellen Regelung eine höhere Regelgüte bei paralleler Senkung des Energiebedarfs zu erreichen. Soll eine Senkung des Energiebedarfs bei gleichbleibender Regelgüte erzielt werden, so muss dies entsprechend im Gütefunktional berücksichtigt werden, da die Optimierungssteuerung die Stellgrößen bezüglich des formulierten Gütefunktionalen optimiert. Hierfür sind die Anforderungen an die Regelung zu erweitern und diese entsprechend in den Metriken zu formulieren.

In der letzten Versuchsreihe wurde eine durchschnittliche Verringerung des Energiebedarfs um ca. 1% festgestellt. Da dieser Wert eine Umsetzung des Verfahrens nicht rechtfertigt, muss weiteres Optimierungspotential der Gesamtregelung des HLK-Systems identifiziert und ausgeschöpft werden. Hierfür ist es erforderlich, den Mikrozyklus erneut zu durchlaufen. Zur Ausnutzung weiteren Optimierungspotentials ist die Einbeziehung weiterer Stellgrößen der Gesamtregelung erforderlich. Hierzu sind zunächst die Stellgrößen Umluftklappe und Gebläsestufe in den modellprädiktiven Ansatz zu integrieren. In der Wiederholung des Mikrozyklus ist die Durchführung einer erneuten Situationsanalyse erforderlich. Dabei sind die Regelziele zu ergänzen und erweiterte Anforderungen zu formulieren. Durch die Umluftklappe wird beispielsweise maßgeblich die Luftgüte in der Fahrzeuggabine bestimmt. Eine Bewertung dieser kann gemäß DIN EN 13779 durch Kategorisierung der gemessenen CO₂-Konzentration in IDA-Werte (vgl. Kapitel 3.2) erfolgen. Zur Untersuchung der Einhaltung dieses Regelziels ist eine Anpassung des thermischen Gesamtfahrzeugmodells notwendig. Nach erfolgter Anpassung des Modells können erneut Versuchsreihen zur Untersuchung der konventionellen Regelung durchgeführt werden und aus den Untersuchungsergebnissen weitere Ziele für die folgenden Systemsynthese- und Analyse-schritte festgelegt werden. Können die hier festgelegten Ziele erreicht werden, so kann ein abschließender Syntheseschritt zur Komposition der modellprädiktiven Regelung aus der modellprädiktiven Steuerung sowie der Rückkopplung erfolgen. Hierbei müssen im Besonderen die Größe des Prognosefensters und des Stellfensters festgelegt und der Einsteuereprozess spezifiziert werden. Wird dieser Syntheseschritt positiv bewertet, kann hiernach im übergeordneten Makrozyklus vorangeschritten werden. Nachdem im allgemeinen Systementwurf das disziplinübergreifende Lösungskonzept festgelegt wurde, kann in den einzelnen Disziplinen mit dem domänenspezifischen Entwurf fortgefahren werden. Integraler Bestandteil des domänenspezifischen Entwurfs ist der folgende Mikrozyklus des Software-Entwicklungsprozesses. Der im allgemeinen Systementwurf entwickelte Lösungsansatz zur modellprädiktiven Regelung dient hierbei als Grundlage der Anforderungserhebung im Requirement Engineerings.

7 Zusammenfassung und Ausblick

Im Vergleich zu verbrennungsmotorisch betriebenen Fahrzeugen weisen batterieelektrisch betriebene Elektrofahrzeuge (BEV) eine signifikant geringere Reichweite auf. Die Innenraumklimatisierung stellt neben dem Antrieb den zweitgrößten Verbraucher in Elektrofahrzeugen dar. Eine Optimierung im Sinne von Maßnahmen zur Reduzierung des Energiebedarfs der Innenraumklimatisierung kann daher wesentlich zur Reichweitensteigerung und somit auch der Marktdurchdringung dieser Technologie beitragen. Der Einsatz einer intelligenten Betriebsstrategie stellt eine kostengünstige Möglichkeit dar, die Effizienz des Gesamtsystems zu steigern und so zur Steigerung der Reichweite batterieelektrisch betriebener Elektrofahrzeuge beizutragen. Ein Ansatz zur Ausschöpfung des vorhandenen Optimierungspotentials im Bereich der Fahrzeugklimatisierung ist die Verwendung Modelprädiktiver Regelungen.

Der Realisierung einer auf diesem Ansatz basierenden Regelung der Fahrzeugklimatisierung stehen mehrere Herausforderungen entgegen. Die wesentliche Voraussetzung für ein befriedigendes Regelungsverhalten ist die hinreichend genaue Vorhersage der betroffenen Regel- und Zustandsgrößen. Werden durch eine unzureichende Berücksichtigung von Störgrößen und durch eine unzureichende Modellierung der ablaufenden technischen Prozesse Regelgrößen falsch vorhergesagt, so werden die Regelabweichungen ebenfalls falsch vorhergesagt, weshalb vorhandenes Optimierungspotential nicht ausgeschöpft werden kann. Methoden des maschinellen Lernens wie z.B. tiefe rekurrente neuronale Netze bieten hierbei eine Alternative zur konventionellen theoretischen, experimentellen oder hybriden Modellbildung.

Im Rahmen dieser Arbeit wurde für eine temperaturregeführte Regelung einer Einzonen-Klimaanlage ein Lösungskonzept zur Umsetzung eines modellprädiktiven Ansatzes basierend auf Verfahren des maschinellen Lernens entwickelt. Der Fokus lag hierbei auf einer Reduzierung des Energiebedarfs bei gleichzeitiger Erfüllung der übernommenen Anforderungen an die konventionelle Regelung. Das Vorgehen in dieser Arbeit basiert auf dem Ist-Zustand-orientierten Vorgehen im Mikrozyklus gemäß VDI-Richtlinie 2206. Ausgehend vom Entwicklungsziel wurde zunächst eine Situationsanalyse des bestehenden Systems durchgeführt. Hierbei wurde, ausgehend von den übernommenen Anforderungen an die konventionelle Regelung, eine Untersuchung der Regelgüte und des Energiebedarfs eines Referenzsystems durchgeführt. Als Referenzsystem diente ein in Zusammenarbeit mit der TLK-Thermo GmbH erstelltes thermisches Gesamtfahrzeugmodell eines BEV. Zur Modellvalidierung wurden reale Straßenversuche mit einem messtechnisch ausgestatteten Elektrofahrzeug vom Typ VW-e-Golf durchgeführt. Die Bewertung der Energieeffizienz erfolgte anhand abgeleiteter Versuchsszenarien aus klimatischen Daten und Pkw-Nutzungsverhalten in Deutschland. Für diese Versuchsszenarien wurden Simulationen am FMU-basierten thermischen Gesamtfahrzeugmodell durchgeführt. Mit den Ergebnissen dieser Untersuchung erfolgte eine Zielformulierung und Anforderungsableitung an den Systementwurf. Hierauf aufbauend wurde ein Grobkonzept für eine modellprädiktive temperaturregeführte Regelung einer Einzonen-Klimaanlage entworfen. Auf Basis dieses Grobkonzepts wurden Untersuchungen zu Lösungsansätzen für die Teilsysteme des Gesamtsystems durchgeführt. Hierfür wurden unter anderem Modelle zur Störgrößenprognose sowie ein Modell zur Abbildung des physikalischen Verhaltens auf Basis von Verfahren des maschinellen Lernens entwickelt. Das Entwicklungsvorgehen zur Modellbildung erfolgte dabei in Anlehnung an das CRISP-DM-Vorgehensmodell. Zur Prädiktion der Störgrößen wurden Verfahren basierend auf einem gewichteten k-Nearest-Neighbor-Ansatz sowie auf gewichteter multivariater Regression umgesetzt. Die Modellbildung des physikalischen Verhaltens des Heizungs-, Lüftungs- und Klimaanlageensystems wie auch der Fahrzeugkabine erfolgte auf Basis eines

tiefen rekurrenten Neuronalen Netzes (LSTM). Hierbei konnte ein sehr effizientes Modell mit sehr hoher Abbildungsgüte erzeugt werden. Während die Rechenzeit einer Versuchsreihe mit insgesamt 700 Stunden simulierter Fahrzeit bei dem konventionellen physikalischen Modell auf einem Intel i7-8700 CPU mit 3,2 GHz 99,3 Stunden betrug, benötigte die Simulation für diese Versuchsreihe durch das neuronale Netz nur 2,01 Sekunden bei nahezu gleicher Abbildungsgenauigkeit. Der Einsatz von LSTM-basierten Modellen zur Abbildung physikalischer Prozesse ist demnach auch neben einer Verwendung in modellprädiktiven Regelungen für weitere Anwendungen geeignet. Auf diese Weise kann z.B. der zeitliche Aufwand für Simulationen im modellbasierten Entwicklungsprozess mechatronischer Systeme signifikant reduziert werden.

Für die Optimierung der Stellgrößen wurde ein Optimalsteuerungsproblem durch ein Gütefunktional formuliert und zur Lösung der Optimierungsaufgabe ein Verfahren basierend auf evolutionären Algorithmen entwickelt. In einer anschließenden Systemsynthese wurden die entwickelten Teilfunktionen zu einem Gesamtsystem integriert und durch experimentelle Untersuchungen im Vergleich zum bestehenden System mit konventioneller Regelung bewertet. Wie die Auswertung zeigt, konnte durch den entworfenen Lösungsansatz das vorhandene Optimierungspotential nahezu vollständig ausgeschöpft werden. Durch Berücksichtigung und Integration weiterer Stellgrößen in den modellprädiktiven Ansatz können weitere Optimierungspotentiale erschlossen werden. Der hierzu notwendige erneute Durchlauf des Mikrozyklus wurde für die zukünftige Weiterentwicklung des Lösungsansatzes beschrieben.

Aufbauend auf der vorliegenden Arbeit sind eine Reihe von Weiterentwicklungen denkbar. So könnte z.B. zur Verbesserung der Vorhersage thermischer Störgrößen eine digitale Echtzeit-Straßenwetterkarte entwickelt werden. Analog zu derzeit etablierten Online-Kartendiensten, die Echtzeit-Verkehrsinformationen für diskrete Straßenabschnitte anbieten, könnten aktuelle Temperaturdaten durch die Fahrzeugsensorik von Einzelfahrzeugen über Car2X-Technologie gewonnen und auf einer digitalen Karte abgebildet werden. Hierdurch kann die Störgrößenprognose verbessert werden, wodurch eine weitere Verbesserung der Ergebnisse des modellprädiktiven Ansatzes zu erwarten ist.

Eine mögliche Weiterentwicklung besteht im Bereich der Optimierung der Stellgrößen. Ein Ansatz wäre, den Optimierungsprozess (durch evolutionäre Algorithmen) durch ein neuronales Netz abzubilden. Hierbei können die durch den aufgezeigten Prozess gewonnenen Optimierungsergebnisse als Trainingsdaten für einen Ansatz des überwachten Lernens dienen. Anstelle der Durchführung jeweils eines Optimierungsprozesses pro Prognosefenster der modellprädiktiven Regelung könnte so das Optimierungs- bzw. Regelgesetz direkt gelernt werden. Durch das hierbei zu trainierende Modell könnten dann direkt aus aktuellen Umgebungsbedingungen und Fahrzeugzuständen die optimalen Trajektorien der Stellgrößen abgeleitet werden. Dieses Verfahren hätte den Vorteil einer extrem kurzen Berechnungsdauer der optimierten Trajektorien. Aufgrund der starken Reduzierung der Rechenzeit können die Zustands- und Störgrößen für jeden Berechnungsschritt aktualisiert werden. Hierdurch ist eine deutliche Verbesserung des Regelverhaltens zu erwarten.

Aufgrund der in dieser Arbeit erzielten erheblichen Reduzierung der Berechnungsdauer bei hoher Prädiktionsgenauigkeit können nun auch Verfahren des bestärkenden Lernens zur Gewinnung optimaler Stellgrößentrajektorien untersucht werden. Das zu ermittelnde Optimierungsgesetz entspricht hierbei der durch den Agenten zu findenden Strategie (Policy). Das in dieser Arbeit entwickelte Prozessmodell könnte dabei als Umgebung, das entwickelte Gütefunktional als Nutzenfunktion zur Ermittlung von Belohnungen oder Bestrafungen eingesetzt werden. Ein weiterer möglicher Ansatz zur Generierung

optimierter Stellgrößentrajektorien könnte auf Basis von GAN (Generative Adversarial Networks) erfolgen. Ein neuronales Netz müsste hierbei zur Generierung geeigneter Lösungskandidaten (Generator), ein zweites neuronales Netz zur Bewertung der Lösungskandidaten (Diskriminator) trainiert werden. Der Diskriminator kann aus dem in dieser Arbeit entwickelten Prozessmodell und dem Gütefunktional direkt abgeleitet werden.

Literaturverzeichnis

- [1] E. Rahimzei, „How does data about energy consumption and range of electric vehicles come about?“, Deutsches Dialog Institut GmbH, Frankfurt am Main, 2015.
- [2] A. Wiebelt und M. Wawzyniak, „Thermal Management for Electrified Vehicles,“ *MTZ Worldwide Volume 77*, p. 38–43, 2016.
- [3] M. Konz, N. Lemke, S. Försterling und M. Eghtessad, „Spezifische Anforderungen an das Heiz-Klimasystem elektromotorisch angetriebener Fahrzeuge,“ Forschungsvereinigung Automobiltechnik e.V. (FAT), Berlin, 2011.
- [4] G. Suck und C. Spengler, „Lösungen für das Wärmemanagement von Batteriefahrzeugen,“ *ATZ - Automobiltechnische Zeitschrift Volume 116*, p. 12–19, 2014.
- [5] H. Grossmann, *Pkw-Klimatisierung - Physikalische Grundlagen und technische Umsetzung*, Karlsruhe: Springer Vieweg, 2013.
- [6] R. Dittmar und B.-M. Pfeiffer, *Modellbasierte prädiktive Regelung - Eine Einführung für Ingenieure*, München: Oldenbourg Verlag, 2004.
- [7] S. Di Cairano, D. Yanakiev, A. Bemporad, I. Kolmanovsky und D. Hrovat, „An MPC Design Flow for Automotive Control and Applications to Idle Speed Regulation,“ in *Proceedings of the 47th IEEE Conference on Decision and Control*, Cancun, Mexico, 2008.
- [8] D. Hrovat, S. Di Cairano, H. Tseng und I. Kolmanovsky, „The Development of Model Predictive Control in Automotive Industry: A Survey,“ in *IEEE International Conference on Control Applications (CCA)*, Dubrovnik, Croatia, 2012.
- [9] M. Back, *Prädiktive Antriebsregelung zum energieoptimalen Betrieb von Hybridfahrzeugen*, Karlsruhe: Dissertation, Universität Karlsruhe, 2005.
- [10] M. Auer, *Ein Beitrag zur Erhöhung der Reichweite durch prädiktives Thermomanagement*, Stuttgart: Dissertation, Universität Stuttgart, 2015.
- [11] H. Esen, T. Tashiro, D. Bernardini und A. Bemporad, „Cabin Heat Thermal Management in Hybrid Vehicles Using Model Predictive Control,“ in *22nd Mediterranean Conference on Control and Automation*, Palermo, Italy, 2014.
- [12] A. Karnik, A. Fuxman, P. Bonkoski, M. Jankovic und J. Pekar, „Vehicle Powertrain Thermal Management System Using Model Predictive Control,“ in *SAE International Journal of Materials and Manufacturing, Vol. 9, No. 3*, Detroit, USA, 2016.

- [13] J. Eckstein, C. Lueke, F. Brunsteina, P. Friedela, U. Koehler und A. Traechtler, „A Novel Approach Using Model Predictive Control to Enhance the Range of Electric Vehicles,“ in *3rd International Conference on System-Integrated Intelligence: New Challenges for Product and Production Engineering, SysInt 2016*, Paderborn, Germany, 2016.
- [14] K. Vatanparvar und M. A. Al Faruque, „Battery Lifetime-Aware Automotive Climate Control for Electric Vehicles,“ in *Proceedings of the 52nd Annual Design Automation Conference (DAC)*, San Francisco, USA, 2015.
- [15] J. Lopez-Sanz, C. Ocampo-Martinez, J. Alvarez-Florez, M. Moreno-Eguilaz, R. Ruiz-Mansilla, J. Kalmus, M. Graeber und G. Lux, „Nonlinear Model Predictive Control for Thermal Management in Plug-in Hybrid Electric Vehicles,“ in *IEEE Transactions on Vehicular Technology, Vol. 66, No. 5*, 2017.
- [16] M. A. Al Faruque und K. Vatanparvar, „Modeling, Analysis, and Optimization of Electric Vehicle HVAC Systems,“ in *21st Asia and South Pacific Design Automation Conference (ASP-DAC)*, Macau, China, 2016.
- [17] M. Graeber, C. Kirches, D. Scharff und W. Tegethoff, „Using Functional Mock-Up Units for Nonlinear Model Predictive Control,“ in *Proceedings of the 9th International Modelica Conference*, Munich, Germany, 2012.
- [18] T. Fischer, T. Kraus, C. Kirches und F. Gauterin, „Nonlinear Model Predictive Control of a Thermal Management System for Electrified Vehicles Using FMI,“ in *Proceedings of the 12th International Modelica Conference*, Prague, Czech Republic, 2017.
- [19] W. J. Grünenfelder und T. Juerg, „The Use of Weather Predictions and Dynamic Programming in the Control of Solar Domestic Hot Water Systems,“ in *Mediterranean Electrotechnical Conference of IEEE Region 8*, Madrid, Spain, 1985.
- [20] G. P. Henze, D. R. H. und M. Krarti, „Development of a Predictive Optimal Controller for Thermal Energy Storage Systems,“ in *International Journal of Heating, Ventilating, Air-Conditioning and Refrigerating Research*, 1997.
- [21] G. P. Henze und M. Krarti, „Predictive Optimal Control of Active and Passive Building Thermal Storage Inventory,“ in *Technical Report, University of Nebraska*, Lincoln, USA, 2003.
- [22] G. P. Henze, D. E. Kalz, S. Liu und C. Felsmann, „Experimental Analysis of Model-Based Predictive Optimal Control for Active and Passive Building Thermal Storage Inventory,“ in *HVAC&R Research, Vol. 11, No. 2*, 2005.
- [23] Y. Zhang und V. I. Hanby, „Short-Term Prediction of Weather Parameters Using Online Weather Forecasts,“ in *Building Simulation (AIVC)*, Beijing, China, 2007.

- [24] F. Oldewurtel, A. Parisio, C. N. Jones, D. Gyalistras, M. Gwerder, V. Stauch, B. Lehmann und M. Morari, „Use of Model Predictive Control and Weather Forecasts for Energy Efficient Building Climate Control,“ in *Energy and Buildings*, Vol. 45, Zurich, Switzerland, 2012.
- [25] B. Dong und K. P. Lam, „A Real-Time Model Predictive Control for Building Heating and Cooling Systems Based on the Occupancy Behavior Pattern Detection and Local Weather Forecasting,“ in *Building Simulation*, Vol. 7, 2014.
- [26] F. Weißel, Stochastische modell-prädiktive Regelung nichtlinearer Systeme, Karlsruhe: Dissertation, Universität Karlsruhe (TH), 2008.
- [27] R. W. Wimmer, Regelung einer Wärmepumpenanlage mit Model Predictive Control, Zürich: Dissertation, ETH Zürich, 2004.
- [28] A. Viehl, R. Valentina, M. R. Zofka und B. Mühr, „Optimized Utilization of E-Vehicle Range Using Route-Based Online Weather Forecast Data,“ in *24th Aachen Colloquium Automobile and Engine Technology 2015*, Aachen, 2015.
- [29] K. Vatanparvar und M. A. Al Faruque, „Eco-Friendly Automotive Climate Control and Navigation System for Electric Vehicles,“ in *Proceedings of the 7th International Conference on Cyber-Physical Systems (ICCPS)*, Vienna, Austria, 2017.
- [30] J. Masino, J. Thumm, M. Frey und F. Gauterin, „Learning from the Crowd: Road Infrastructure Monitoring System,“ in *Journal of Traffic and Transportation Engineering*, Vol. 4, No. 5, Karlsruhe, Germany, 2017.
- [31] K. Schröder, S. Wagner und M. Ellinger, „Gekoppelte Simulation der Klimaanlage und Fahrgastzelle unter Berücksichtigung variierender Randbedingungen,“ in *PKW_Klimatisierung II- Klimakonzepte, Regelungsstrategien und Entwicklungsmethoden heute und in Zukunft*, Essen, Expert Verlag, 2002, pp. 210-223.
- [32] H. Tummescheit, J. Eborn, K. Proessl, S. Foersterling und W. Tegethoff, „AirConditioning: Eine Modelica-Bibliothek zur dynamischen Simulation von Kältekreisläufen,“ in *PKW-Klimatisierung IV- Klimakonzepte, Zuheizkonzepte, Regelungsstrategien und Entwicklungsmethoden*, Essen, Expert Verlag, 2007, pp. 196-214.
- [33] R. Domschke und M. Matthes, „In-the-Loop Simulation of Electronic Automatic Temperature Control Systems: HVAC Modeling,“ in *PKW-Klimatisierung IV- Klimakonzepte, Zuheizkonzepte, Regelungsstrategien und Entwicklungsmethoden*, Essen, expert verlag, 2006, pp. 215-231.
- [34] K. Martin, R. Rieberer, S. Alber, J.-J. Robin und T. Schaefer, „Einsatz von numerischer Simulation bei der Entwicklung von Kältekreisläufen,“ in *PKW-Klimatisierung V-Effiziente Kältekreisläufe, Klimakonzepte für Hybridfahrzeuge und Strategien zur Komfortverbesserung*, Essen, expert verlag, 2007, pp. 77-91.

- [35] S. Park, A Comprehensive Thermal Management System Model for Hybrid Electric Vehicles, Michigan, USA: Dissertation, University of Michigan, 2011.
- [36] C. Haupt, Ein multiphysikalisches Simulationsmodell zur Bewertung von Antriebs- und Wärmemanagementkonzepten im Kraftfahrzeug, München: Dissertation, TU München, 2012.
- [37] B. Flieger, Innenraummodellierung einer Fahrzeugkabine in der Programmiersprache Modelica, Aachen: Dissertation, RWTH Aachen, 2013.
- [38] D. Marcos, F. J. Pino, B. Carlos und J. J. Guerra, „The Development and Validation of a Thermal Model for the Cabin of a Vehicle,“ in *Applied Thermal Engineering, Vol. 66, No. 1-2*, 2014.
- [39] M. Fritz, Entwicklungswerkzeuge für die Fahrzeugklimatisierung von Nutzfahrzeugen, Karlsruhe: Dissertation, Karlsruher Institut für Technologie, 2015.
- [40] F. Schueppel, Optimierung des Heiz- und Klimakonzepts zur Reduktion der Wärme- und Kälteleistung im Fahrzeug, Berlin: Dissertation, TU Berlin, 2015.
- [41] F. Netter, Komplexitätsadaption integrierter Gesamtfahrzeugsimulationen, Karlsruhe: Dissertation, Karlsruher Institut für Technologie, 2015.
- [42] D. Moller, J. Aurich, R. Tröger und C. Grünig, „Gesamtheitliche Betrachtung des Thermomanagements in Elektrofahrzeugen - Interaktion der Klima- und Kühlsystemkomponenten im Gesamtverbund,“ in *19. MTZ-Fachtagung Simulation und Test*, Darmstadt, 2017.
- [43] R. Baumgart, Reduzierung des Kraftstoffverbrauches durch Optimierung von Pkw-Klimaanlagen, Chemnitz: Dissertation, TU Chemnitz, 2010.
- [44] T.-Y. Lee, Prediction of Car Cabin Temperature Using Artificial Neural Network, München: Master-Thesis, Technische Universität München, 2007.
- [45] T. Lu und M. Viljanen, „Prediction of Indoor Temperature and Relative Humidity Using Neural Network Models: Model Comparison,“ in *Neural Computing and Applications 18, No. 345*, Espoo, Finnland, 2008.
- [46] G. Mustafarraj, J. Chen und G. Lowry, „Thermal Behavior Prediction Utilizing Artificial Neural Networks for an Open Office,“ in *Applied Mathematical Modelling, Vol. 34, No. 11*, Uxbridge, Middlesex, United Kingdom, 2010.
- [47] A. E. Ruano und P. M. Ferreira, „Neural Network based HVAC Predictive Control,“ in *IFAC Proceedings Volumes, Vol 47., No. 3*, Cape Town, South Africa, 2014.
- [48] T. Knohl, Anwendung künstlich neuronaler Netze zur nichtlinearen adaptiven Regelung, Bochum: Dissertation, Ruhr-Universität Bochum, 2000.

- [49] M. Rau, Nichtlineare Modellbasierte prädiktive Regelung auf Basis lernfähiger Zustandsraummodelle, München: Dissertation, Technische Universität München, 2003.
- [50] T. L. Schmitt und M. Andres, Methoden zur Modellbildung und Simulation mechatronischer Systeme, Dornbirn, Österreich: Springer Vieweg, 2019.
- [51] H. Unbehauen, Regelungstechnik I, Bochum: Vieweg+Teubner Verlag, 2008.
- [52] S. Vajna, C. Weber, H. Bley und K. Zeman, CAx für Ingenieure, Berlin Heidelberg: Springer-Verlag, 2009.
- [53] R. Isermann, Mechatronische Systeme - Grundlagen, Berlin Heidelberg : Springer-Verlag, 2008.
- [54] VDI 3633 - Simulation von Logistik-, Materialfluss- und Produktionssystemen, Verein Deutscher Ingenieure, Mai 2018.
- [55] P. Engel, S. Meise, A. Rausch und T. Wilhelm, „Modeling of Automotive HVAC Systems Using Long Short-Term Memory Networks,“ in *The Eleventh International Conference on Adaptive and Self-Adaptive Systems and Applications*, Venice, Italy, 2019.
- [56] A. Eichhorn, Ein Beitrag zur Identifikation von dynamischen Strukturmodellen mit Methoden der adaptiven KALMAN-Filterung, Stuttgart: Dissertation, Universität Stuttgart, 2004.
- [57] W. Tegethoff, C. Schulze, M. Gräber, M. Huhn, N. Stulgies, C. Kaiser und M. Loeffler, „Thermische Echtzeitfähige Modelle,“ Abschlussbericht zum BMBF Verbundvorhaben TEMO, Braunschweig, 2011.
- [58] H. D. Baehr, Thermodynamik, Berlin: Springer-Verlag, 2002.
- [59] D. Ghebru, Modellierung und Analyse des instationären thermischen Verhaltens von Verbrennungsmotor und Gesamtfahrzeug, Karlsruhe: Dissertation, Karlsruher Institut für Technologie, 2013.
- [60] V. Quaschnig, Regenerative Energiesysteme, München: Carl Hanser Verlag, 2015.
- [61] M. A. Fayazbakhsh und M. Bahrami, „Comprehensive Modeling of Vehicle Air Conditioning Loads Using Heat Balance Method,“ in *SAE Technical Paper 2013-01-1507*, 2013.
- [62] H. S. Fischer und H. Gilgen, „DACHRad – Berechnung der direkten Sonneneinstrahlung in Deutschland, Österreich und der Schweiz,“ in *Bulletin of the Geobotanical Institute ETH*, Zürich, Schweiz, 2002.
- [63] FNL, Normenausschuß Lichttechnik, „DIN 5034 Tageslicht in Innenräumen,“ Deutsches Institut für Normung e.V., Berlin, 1985.
- [64] F. Linke, „Transmissions-Koeffizient und Trübungsfaktor,“ in *Beiträge zur Physik der Atmosphäre, Vol. 10*, 1922.

- [65] A. Geron, Hands-On Machine Learning with Scikit-Learn and Tensorflow, O'Reilly, 2017.
- [66] E. Alpaydin, Maschinelles Lernen, München: Oldenbourg Wissenschaftsverlag, 2008.
- [67] A. Zell, Simulation neuronaler Netze, München: R. Oldenbourg Verlag, 1997.
- [68] M. L. Minsky und S. A. Papert, Perceptrons: An Introduction to Computational Geometry, Cambridge, Massachusetts, USA: The MIT Press, 1969.
- [69] K. Hornik, M. Stichcombe und H. White, „Multilayer Feedforward Networks are Universal Approximators,“ in *Neural Networks, Vol. 2, No. 5*, 1989.
- [70] C. Cybenko, „Approximation by Superposition of Sigmoidal Function,“ in *Mathematics of Control, Signals and Systems, Vol. 2*, 1989.
- [71] S. Ioffe und C. Szegedy, „Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,“ in *Proceedings of The 32nd International Conference on Machine Learning, Vol. 37*, 2015.
- [72] G. Klambauer, T. Unterthiner, A. Mayr und S. Hochreiter, „Self-Normalizing Neural Networks,“ in *In Advances in Neural Information Processing Systems (NIPS), Vol. 30*, 2017.
- [73] Y. E. Nesterov, „A method for unconstrained convex minimization problem with the rate of convergence $O(1/k^2)$,“ in *Doklady AN USSR, Vol. 269*, 1983.
- [74] S. Hochreiter und J. Schmidhuber, „Long Short-Term Memory,“ in *Neural Computation, Vol. 9, No. 8*, 1997.
- [75] J. A. Rossiter, Model-Based Predictive Control: A Practical Approach, London: CRC Press, 2003.
- [76] M. Diehl, H. G. Bock, H. Diedam und P.-B. Wieber, „Fast Direct Multiple Shooting Algorithms for Optimal Robot Control,“ in *Fast Motions in Biomechanics and Robotics, Vol. 340*, Heidelberg, Germany, 2005.
- [77] M. Papageorgiou, M. Leibold und M. Buss, Optimierung- Statische, dynamische, stochastische Verfahren für die Anwendung, Berlin: Springer Vieweg, 2015.
- [78] M. Ulbrich und S. Ulbrich, Nichtlineare Optimierung, München und Darmstadt: Springer Basel, 2012.
- [79] D. B. Leineweber, The Theory of MUSCOD in a Nutshell, Heidelberg: Diplomarbeit, Universität Heidelberg, 1995.
- [80] T. F. Coleman und Y. Li, „A Reflective Newton Method for Minimizing a Quadratic Function Subject to Bounds on Some of the Variables,“ in *SIAM Journal on Optimization, Vol 6., No. 4*, 1996.

- [81] P. E. Gill, W. Murray und M. H. Wright , Practical Optimization, London, UK: Emerald Group Publishing Limited, 1982.
- [82] N. Gould und P. L. Toint, „Preprocessing for Quadratic Programming,“ in *Mathematical Programming, Vol. 100*, 2004.
- [83] C. Geiger und C. Kanzow, Theorie und Numerik restringierter Optimierungsaufgaben, Berlin: Springer-Verlag, 2002.
- [84] M. Diehl, D. B. Leineweber und A. A. Schäfer, MUSCOD-II Users' Manual, Heidelberg: Interdisziplinäres Zentrum für Wissenschaftliches Rechnen, 2001.
- [85] C.-A. Hoffmann, Methodik zur Steuerung modularer Produktbaukästen, Braunschweig: Dissertation, TU Braunschweig, 2017.
- [86] H.-H. Braess und U. Seiffert, Vieweg Handbuch Kraftfahrzeugtechnik, Wiesbaden: Springer Vieweg, 2013.
- [87] I. Göpfert, Logistik der Zukunft – Logistics for the Future, Marburg: Springer Gabler, 2016.
- [88] R. G. Cooper, „Perspective: The Stage-Gates Idea-to-Launch Process-Update, What’s New, and NexGen Systems,“ in *Journal of Product Innovation Management, Vol. 25, No. 3* , 2008.
- [89] VDA QMC Working Group 13 / Automotive SIG , *Automotive SPICE Process Assessment / Reference Model*, 2017.
- [90] J. Bach, Methoden und Ansätze für die Entwicklung und den Test prädiktiver Fahrzeugregelungsfunktionen, Karlsruhe: Dissertation, Karlsruher Instituts für Technologie, 2018.
- [91] A. Wyrwoll, *CID - Customer Integration Deployment: Entwicklung einer Methode zur Integration der Kunden in die frühen Phasen des Produktentstehungsprozesses am Beispiel der Automobilindustrie*, Chemnitz: GUC, Gesellschaft für Unternehmensrechnung und Controlling, 2001.
- [92] Verein Deutscher Ingenieure - Ausschuss Entwicklungsmethodik für mechatronische Systeme, *VDI 2206 - Entwicklungsmethodik für mechatronische Systeme*, Beuth Verlag GmbH, 2004.
- [93] D. Michalek, C. Gehsat, R. Trapp und T. Bertram, „Hardware-in-the-Loop-Simulation of a Vehicle Climate Controller with a Combined HVAC and Passenger Compartment Model,“ in *Proceedings of the 2005 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, Monterey, California, USA, 2005.
- [94] R. Trapp und C. Gehsat, „Modellbasierter Entwicklungsprozess von Klimasteuergeräten,“ in *ATZelektronik, Vol. 2*, 2007.

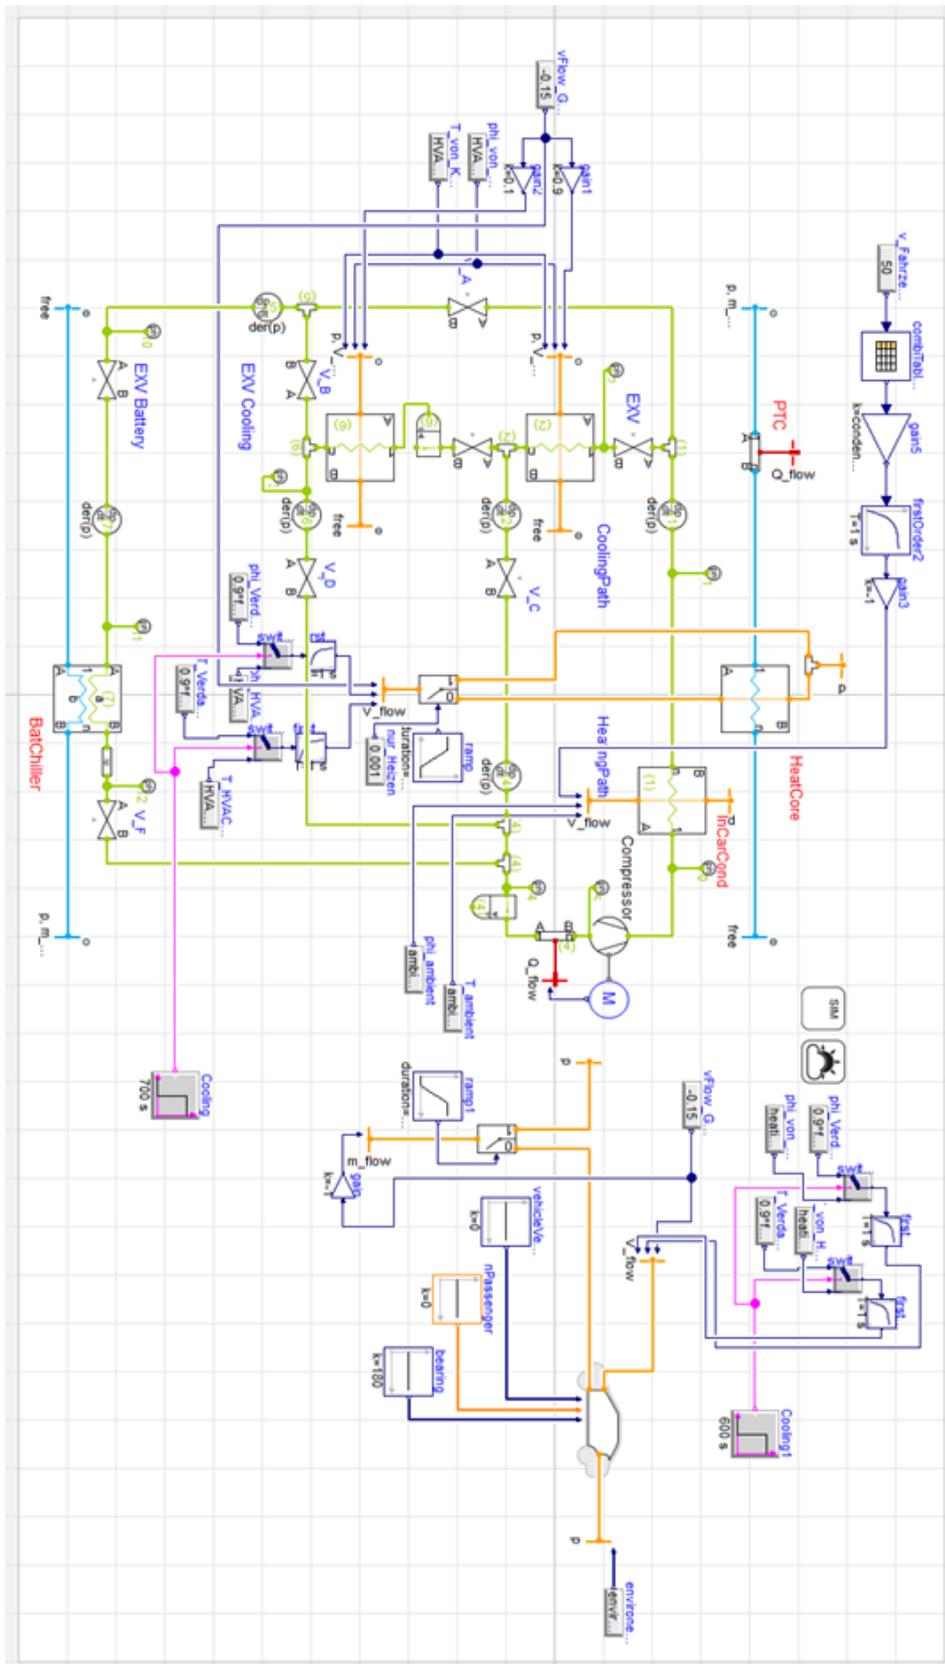
- [95] R. Trapp, „Vorrichtung zur Regelung eines Kältekreislaufs für eine Kraftfahrzeug-Klimaanlage“. DE Patent EP2184568, 24 Juni 2010.
- [96] T. Wetzel, J. Matthias, R. Gneiting, K. Wustlich und O. Getto, „Zusammenspiel von Simulation und Versuch - Entwicklung effizienter Klimasysteme,“ in *ATZextra*, Vol. 13, 2008.
- [97] H. Großmann, „Heizung, Lüftung, Klimatisierung von Pkw,“ in *Aerodynamik des Automobils*, Wiesbaden, Springer Fachmedien, 2005, p. 757.
- [98] FAKRA, Normenausschuss Kraftfahrzeuge, *DIN 1946-3 Raumluftechnik – Teil 3: Klimatisierung von Personenkraftwagen und Lastkraftwagen*, Berlin: Deutsches Institut für Normung e.V., 2006.
- [99] P. O. Fanger, *Thermal comfort: Analysis and Applications in Environmental Engineering*, Kopenhagen, Dänemark: Danish Technical Press, 1970.
- [100] NAERG, Normenausschuss Ergonomie, *DIN EN ISO 7730, Ergonomie der thermischen Umgebung – Analytische Bestimmung und Interpretation der thermischen Behaglichkeit durch Berechnung des PMV- und des PPD-Indexes und Kriterien der lokalen thermischen Behaglichkeit*, Berlin: DIN Deutsches Institut für Normung e.V., 2006.
- [101] Ad-hoc-Arbeitsgruppe der Innenraumlufthygiene-Kommission des Umweltbundesamtes und der Obersten Landesgesundheitsbehörden, *Gesundheitliche Bewertung von Kohlendioxid in der Innenraumluft*, Bekanntmachung des Umweltbundesamtes, 2008.
- [102] F. Wolf, *Fahrzeuginformatik - Eine Einführung in die Software- und Elektronikentwicklung aus der Praxis der Eine Einführung in die Software- und*, Wiesbaden: Springer Vieweg, 2018.
- [103] Volkswagen AG, *Self-Study Programme 208- Air Conditioner in the Motor Vehicle*, Wolfsburg: Selbststudienprogramm, Volkswagen AG, 1998.
- [104] V. AG, *Self-Study Programme 527- The E-Up*, Wolfsburg: Selbststudienprogramm, Volkswagen AG, 2014.
- [105] F. Bohlender und H. Reiss, „Elektrische Innenraumheizung von E-Fahrzeugen Per PTC-System,“ in *ATZ - Automobiltechnische Zeitschrift*, Vol.115, Nr. 2, 2013.
- [106] K. Granse, H. Wieszt und J. Wilhelm, „Verfahren zur Regelung einer Heiz- und/oder Klimaanlage“. Patent DE19942529C1, 07 September 1999.
- [107] E. Schlaudraff, „Betriebsverfahren für eine Fahrzeug-Heiz- oder Klimaanlage mit einem Automatikprogramm“. Patent DE19637411A1, 13 September 1996.
- [108] O. Neumann und E. Pott, „Klimaanlage für ein Verkehrsmittel mit Automatik- und Individualbetrieb“. Patent DE4426732C2, 13 August 1993.

- [109] J. Desarthe, „Air-Conditioning System Motor Vehicle Interior“. Patent DE4306015A1, 28 Februar 1992.
- [110] K. Helms, „Method for Controlling the Air-Conditioning of a Vehicle Interior“. Patent EP2507082B1, 05 Dezember 2009.
- [111] C. Strupp und N. Lempke, *Klimatische Daten und Pkw-Nutzung - Klimadaten und Nutzungsverhalten zu Auslegung, Versuch und Simulation an Kraftfahrzeug-Kälte-/Heizanlagen in Europa, USA, China und Indien*, Braunschweig: Forschungsvereinigung Automobiltechnik e.V. (FAT), 2009.
- [112] A. Strasser, P. Engel, S. Lempp, M. Schindler und W. Tegethoff, „A Component Catalog Platform for The Integrated Development of Simulation Models In The Automotive HVAC Domain,“ in *ESES 2020: Evolving Software Ecosystems and Services*, Nice, France, 2020.
- [113] S. Lempp, Effizienzsteigerung der Heizung und Kühlung von batterieelektrisch angetriebenen Stadtbussen, Braunschweig: Dissertation, Technische Universität Braunschweig, 2021.
- [114] P. Engel, S. Lempp, A. Rausch und W. Tegethoff, „Modeling of Automotive HVAC Systems Using Long Short-Term Memory Networks,“ in *ADAPTIVE 2019 : The Eleventh International Conference on Adaptive and Self-Adaptive Systems and Applications*, Venice, Italy, 2019.
- [115] TLK-Thermo, *TIL Suite: Software Package to Simulate Thermal Systems*, Braunschweig: TLK-Thermo GmbH, 2019.
- [116] TLK-Thermo, *TIL AddOn Automotive: Software Package to Simulate Thermal Systems with Focus on Automolie Applications*, Braunschweig: TLK-Thermo GmbH, 2019.
- [117] W. Rohsenow, J. Hartnett und E. Ganic, *Handbook of Heat Transfer Fundamentals* (2nd Edition), United States: McGraw-Hill, 1985.
- [118] F. Dittus und L. Boelter, „Heat Transfer in Automobile Radiators of the Tubular Type,“ in *Publications in Engineering, University of California, Vol. 2, No. 443*, Berkeley, United States, 1930.
- [119] V. Gnielinski, „Neue Gleichungen für den Wärme- und den Stoffübergang in turbulent durchströmten Rohren und Kanälen,“ in *Forschung im Ingenieurwesen, Vol. 21*, 1975.
- [120] S. Haaf, „Wärmeübertragung in Luftkühlern,“ in *Wärmeaustauscher. Handbuch der Kältetechnik Vol. 6*, Springer-Verlag, Berlin, Heidelberg, 1988.
- [121] W. H. McAdams, W. K. Woods und L. C. Heroman, „Vaporization Inside Horizontal Tubes-II- Benzene-Oil Mixtures,“ in *Trans. American Society of Mechanical Engineers, Vol. 64, No. 3*, 1942.
- [122] P. K. Swamee und A. K. Jain, „Explicit Equations for Pipe-Flow Problems,“ in *Journal of the Hydraulics Division, American Society of Civil Engineers, Vol. 102, No. 5*, 1976.

- [123] Modelica Association, „www.modelica.org, Linköpings Universitet, Sweden,“ [Online]. Available: https://www.modelica.org/publications/newsletters/2010-1/index_html#item8. [Zugriff am 24 März 2020].
- [124] L. A. Kurgan und M. Petr, „A Survey of Knowledge Discovery and Data Mining Process Models,“ in *The Knowledge Engineering Review*, Vol. 21, No. 1, 2006.
- [125] P. Engel, S. Meise, A. Rausch und W. Tegethoff, „Improving Thermal Management of Electric Vehicles by Prediction of Thermal Disturbance Variables,“ in *ADAPTIVE 2018 : The Tenth International Conference on Adaptive and Self-Adaptive Systems and Applications*, Barcelona, Spain, 2018.
- [126] B. Klose und H. Klose, *Meteorologie*, Oldenburg: Springer Spektrum, 2016.
- [127] R. Wengenmayr und G. Lux, „Wie gut sind Wettervorhersagen?- Qualitätsprüfung beim DWD,“ Deutscher Wetterdienst, Offenbach, Germany, 2008.
- [128] A. Rezaei und J. B. Burl, „Prediction of Vehicle Velocity for Model Predictive Control,“ in *IFAC-PapersOnLine*, Vol. 48, No. 15 , 2015.
- [129] K. Liu, Z. Asher, X. Gong und M. Huang, „Vehicle Velocity Prediction and Energy Management Strategy Part 1: Deterministic and Stochastic Vehicle Velocity Prediction Using Machine Learning,“ in *SAE Technical Paper 2019-01-1051*, 2019.
- [130] S. A. Dudani, „The Distance-Weighted k-Nearest-Neighbor Rule,“ in *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-6, No. 4, Malibu, USA, 1976.
- [131] A. Strobel, *Verteilte nichtlineare modellprädiktive Regelung von unbemannten Luftfahrzeug-Schwärmen*, Darmstadt: Dissertation, Technischen Universität Darmstadt, 2016.
- [132] K. Weicker, *Evolutionäre Algorithmen*, Wiesbaden: Springer Vieweg, 2015.

A. Anhang

Anhang A.1 Modelica-Gesamtmodell des HLK-Systems und der Fahrzeugkabine



Anhang A.4 Laufende Nummerierung der Versuchsszenarien in 3 Versuchsreihen

		-25°C- -20°C	-20°C - -15°C	-15°C- -10°C	-10°C - -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ ψ < 100 W/m ²	20 < ϕ ≤ 40	1	2	3	4	5	6	7	8	9	10	11	12	Versuchsreihe I Umgebungsgrößen statisch
	40 < ϕ ≤ 60	13	14	15	16	17	18	19	20	21	22	23	24	
	60 < ϕ ≤ 80	25	26	27	28	29	30	31	32	33	34	35	36	
	80 < ϕ ≤ 100	37	38	39	40	41	42	43	44	45	46	47	48	
100 W/m ² < ψ ψ < 500 W/m ²	20 < ϕ ≤ 40	49	50	51	52	53	54	55	56	57	58	59	60	
	40 < ϕ ≤ 60	61	62	63	64	65	66	67	68	69	70	71	72	
	60 < ϕ ≤ 80	73	74	75	76	77	78	79	80	81	82	83	84	
	80 < ϕ ≤ 100	85	86	87	88	89	90	91	92	93	94	95	96	
500 W/m ² < ψ ψ < 900 W/m ²	20 < ϕ ≤ 40	97	98	99	100	101	102	103	104	105	106	107	108	
	40 < ϕ ≤ 60	109	110	111	112	113	114	115	116	117	118	119	120	
	60 < ϕ ≤ 80	121	122	123	124	125	126	127	128	129	130	131	132	
	80 < ϕ ≤ 100	133	134	135	136	137	138	139	140	141	142	143	144	
ψ < 900 W/m ²	20 < ϕ ≤ 40	145	146	147	148	149	150	151	152	153	154	155	156	
	40 < ϕ ≤ 60	157	158	159	160	161	162	163	164	165	166	167	168	
	60 < ϕ ≤ 80	169	170	171	172	173	174	175	176	177	178	179	180	
	80 < ϕ ≤ 100	181	182	183	184	185	186	187	188	189	190	191	192	
0 W/m ² < ψ ψ < 100 W/m ²	20 < ϕ ≤ 40	193	194	195	196	197	198	199	200	201	202	203	204	
	40 < ϕ ≤ 60	205	206	207	208	209	210	211	212	213	214	215	216	
	60 < ϕ ≤ 80	217	218	219	220	221	222	223	224	225	226	227	228	
	80 < ϕ ≤ 100	229	230	231	232	233	234	235	236	237	238	239	240	
100 W/m ² < ψ ψ < 500 W/m ²	20 < ϕ ≤ 40	241	242	243	244	245	246	247	248	249	250	251	252	
	40 < ϕ ≤ 60	253	254	255	256	257	258	259	260	261	262	263	264	
	60 < ϕ ≤ 80	265	266	267	268	269	270	271	272	273	274	275	276	
	80 < ϕ ≤ 100	277	278	279	280	281	282	283	284	285	286	287	288	
500 W/m ² < ψ ψ < 900 W/m ²	20 < ϕ ≤ 40	289	290	291	292	293	294	295	296	297	298	299	300	
	40 < ϕ ≤ 60	301	302	303	304	305	306	307	308	309	310	311	312	
	60 < ϕ ≤ 80	313	314	315	316	317	318	319	320	321	322	323	324	
	80 < ϕ ≤ 100	325	326	327	328	329	330	331	332	333	334	335	336	
ψ < 900 W/m ²	20 < ϕ ≤ 40	337	338	339	340	341	342	343	344	345	346	347	348	
	40 < ϕ ≤ 60	349	350	351	352	353	354	355	356	357	358	359	360	
	60 < ϕ ≤ 80	361	362	363	364	365	366	367	368	369	370	371	372	
	80 < ϕ ≤ 100	373	374	375	376	377	378	379	380	381	382	383	384	
0 W/m ² < ψ ψ < 100 W/m ²	20 < ϕ ≤ 40	385	386	387	388	389	390	391	392	393	394	395	396	
	40 < ϕ ≤ 60	397	398	399	400	401	402	403	404	405	406	407	408	
	60 < ϕ ≤ 80	409	410	411	412	413	414	415	416	417	418	419	420	
	80 < ϕ ≤ 100	421	422	423	424	425	426	427	428	429	430	431	432	
100 W/m ² < ψ ψ < 500 W/m ²	20 < ϕ ≤ 40	433	434	435	436	437	438	439	440	441	442	443	444	
	40 < ϕ ≤ 60	445	446	447	448	449	450	451	452	453	454	455	456	
	60 < ϕ ≤ 80	457	458	459	460	461	462	463	464	465	466	467	468	
	80 < ϕ ≤ 100	469	470	471	472	473	474	475	476	477	478	479	480	
500 W/m ² < ψ ψ < 900 W/m ²	20 < ϕ ≤ 40	481	482	483	484	485	486	487	488	489	490	491	492	
	40 < ϕ ≤ 60	493	494	495	496	497	498	499	500	501	502	503	504	
	60 < ϕ ≤ 80	505	506	507	508	509	510	511	512	513	514	515	516	
	80 < ϕ ≤ 100	517	518	519	520	521	522	523	524	525	526	527	528	
ψ < 900 W/m ²	20 < ϕ ≤ 40	529	530	531	532	533	534	535	536	537	538	539	540	
	40 < ϕ ≤ 60	541	542	543	544	545	546	547	548	549	550	551	552	
	60 < ϕ ≤ 80	553	554	555	556	557	558	559	560	561	562	563	564	
	80 < ϕ ≤ 100	565	566	567	568	569	570	571	572	573	574	575	576	

Anhang A.5 Situationsanalyse - Bewertung der Regelgüte nach Metrik 1

		-25°C- -20°C	-20°C - -15°C	-15°C- -10°C	-10°C - -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ ψ < 100 W/m ²	20 < φ ≤ 40	0,662	0,570	0,429	0,304	0,188	0,082	0,012	0,069	0,208	0,402	0,495	0,526	Versuchsreihe I Umgebungsgrößen statisch
	40 < φ ≤ 60	0,662	0,570	0,429	0,304	0,188	0,082	0,012	0,069	0,207	0,400	0,494	0,526	
	60 < φ ≤ 80	0,662	0,570	0,429	0,304	0,188	0,082	0,012	0,068	0,204	0,402	0,494	0,527	
	80 < φ ≤ 100	0,662	0,570	0,429	0,304	0,188	0,082	0,012	0,068	0,208	0,399	0,495	0,525	
100 W/m ² < ψ ψ < 500 W/m ²	20 < φ ≤ 40	0,657	0,566	0,427	0,302	0,186	0,080	0,011	0,207	0,430	0,492	0,486	0,516	
	40 < φ ≤ 60	0,657	0,566	0,427	0,302	0,186	0,080	0,011	0,207	0,429	0,492	0,481	0,516	
	60 < φ ≤ 80	0,657	0,566	0,427	0,302	0,186	0,080	0,011	0,207	0,430	0,492	0,480	0,518	
	80 < φ ≤ 100	0,657	0,566	0,427	0,302	0,186	0,080	0,011	0,210	0,428	0,485	0,482	0,514	
500 W/m ² < ψ ψ < 900 W/m ²	20 < φ ≤ 40	0,650	0,561	0,424	0,299	0,183	0,077	0,345	0,446	0,465	0,408	0,764	1,442	
	40 < φ ≤ 60	0,650	0,561	0,424	0,299	0,183	0,077	0,340	0,445	0,467	0,413	0,764	1,439	
	60 < φ ≤ 80	0,650	0,561	0,424	0,299	0,183	0,077	0,339	0,451	0,467	0,413	0,760	1,436	
	80 < φ ≤ 100	0,650	0,561	0,424	0,299	0,183	0,077	0,339	0,451	0,467	0,414	0,761	1,437	
ψ < 900 W/m ²	20 < φ ≤ 40	0,647	0,559	0,422	0,297	0,182	0,294	0,423	0,449	0,510	1,191	2,014	2,781	
	40 < φ ≤ 60	0,647	0,559	0,422	0,297	0,182	0,296	0,424	0,451	0,509	1,191	2,018	2,778	
	60 < φ ≤ 80	0,647	0,559	0,422	0,297	0,182	0,296	0,425	0,446	0,509	1,191	2,018	2,781	
	80 < φ ≤ 100	0,647	0,559	0,422	0,297	0,182	0,296	0,424	0,445	0,509	1,191	2,018	2,777	
0 W/m ² < ψ ψ < 100 W/m ²	20 < φ ≤ 40	0,664	0,599	0,452	0,326	0,207	0,101	0,010	0,065	0,231	0,425	0,496	0,531	Versuchsreihe II Umgebungsgrößen dynamisch
	40 < φ ≤ 60	0,664	0,599	0,452	0,326	0,207	0,101	0,010	0,065	0,234	0,424	0,496	0,531	
	60 < φ ≤ 80	0,664	0,599	0,452	0,326	0,207	0,101	0,010	0,065	0,234	0,421	0,497	0,531	
	80 < φ ≤ 100	0,664	0,599	0,452	0,326	0,207	0,101	0,010	0,065	0,233	0,419	0,496	0,528	
100 W/m ² < ψ ψ < 500 W/m ²	20 < φ ≤ 40	0,658	0,575	0,434	0,308	0,192	0,085	0,009	0,210	0,423	0,495	0,500	0,509	
	40 < φ ≤ 60	0,658	0,575	0,434	0,308	0,192	0,085	0,009	0,210	0,423	0,493	0,498	0,506	
	60 < φ ≤ 80	0,658	0,575	0,434	0,308	0,192	0,085	0,009	0,208	0,424	0,494	0,498	0,505	
	80 < φ ≤ 100	0,658	0,575	0,434	0,308	0,192	0,085	0,009	0,209	0,424	0,492	0,496	0,505	
500 W/m ² < ψ ψ < 900 W/m ²	20 < φ ≤ 40	0,657	0,595	0,449	0,323	0,237	0,265	0,323	0,390	0,636	1,125	1,744	2,337	
	40 < φ ≤ 60	0,657	0,595	0,449	0,323	0,237	0,264	0,323	0,390	0,631	1,125	1,743	2,336	
	60 < φ ≤ 80	0,657	0,595	0,449	0,323	0,237	0,265	0,324	0,388	0,630	1,121	1,739	2,336	
	80 < φ ≤ 100	0,657	0,595	0,449	0,323	0,236	0,264	0,326	0,390	0,629	1,120	1,736	2,330	
ψ < 900 W/m ²	20 < φ ≤ 40	0,662	0,647	0,487	0,362	0,968	0,547	0,386	0,666	1,457	2,182	2,949	3,670	
	40 < φ ≤ 60	0,662	0,647	0,487	0,362	0,967	0,530	0,386	0,665	1,456	2,185	2,948	3,669	
	60 < φ ≤ 80	0,662	0,647	0,487	0,362	0,966	0,555	0,388	0,670	1,456	2,181	2,948	3,671	
	80 < φ ≤ 100	0,662	0,647	0,487	0,362	0,966	0,554	0,388	0,673	1,458	2,181	2,950	3,669	
0 W/m ² < ψ ψ < 100 W/m ²	20 < φ ≤ 40	19,873	17,063	13,708	10,415	7,185	4,024	0,939	0,069	0,208	0,402	0,495	0,526	Versuchsreihe III Begrenztes Energiebudget
	40 < φ ≤ 60	19,873	17,064	13,708	10,416	7,186	4,024	0,939	0,069	0,207	0,400	0,494	0,526	
	60 < φ ≤ 80	19,873	17,064	13,709	10,416	7,186	4,024	0,942	0,068	0,204	0,402	0,494	0,527	
	80 < φ ≤ 100	19,873	17,064	13,709	10,417	7,193	4,025	0,942	0,068	0,208	0,399	0,495	0,525	
100 W/m ² < ψ ψ < 500 W/m ²	20 < φ ≤ 40	17,230	14,416	11,051	7,751	4,512	1,315	0,011	0,207	0,430	0,492	0,486	0,516	
	40 < φ ≤ 60	17,230	14,416	11,051	7,752	4,518	1,316	0,011	0,207	0,429	0,492	0,481	0,516	
	60 < φ ≤ 80	17,230	14,416	11,052	7,752	4,518	1,319	0,011	0,207	0,430	0,492	0,480	0,518	
	80 < φ ≤ 100	17,231	14,416	11,052	7,753	4,519	1,319	0,011	0,210	0,428	0,485	0,482	0,514	
500 W/m ² < ψ ψ < 900 W/m ²	20 < φ ≤ 40	12,988	10,168	6,786	3,470	0,207	0,077	0,345	0,446	0,465	0,408	0,764	1,442	
	40 < φ ≤ 60	12,988	10,169	6,787	3,470	0,209	0,077	0,340	0,445	0,467	0,413	0,764	1,439	
	60 < φ ≤ 80	12,988	10,169	6,787	3,475	0,210	0,077	0,339	0,451	0,467	0,413	0,760	1,436	
	80 < φ ≤ 100	12,989	10,169	6,793	3,475	0,210	0,077	0,339	0,451	0,467	0,414	0,761	1,567	
ψ < 900 W/m ²	20 < φ ≤ 40	10,862	8,045	4,648	1,326	0,182	0,294	0,423	0,449	0,510	1,191	2,014	2,781	
	40 < φ ≤ 60	10,862	8,045	4,648	1,327	0,182	0,296	0,424	0,451	0,509	1,191	2,018	2,778	
	60 < φ ≤ 80	10,863	8,045	4,654	1,327	0,182	0,296	0,425	0,446	0,509	1,191	2,018	2,781	
	80 < φ ≤ 100	10,863	8,046	4,654	1,330	0,182	0,296	0,424	0,445	0,509	1,191	2,018	3,513	

Anhang A.7 Situationsanalyse - Auswertung des Energiebedarfs Verdichter

		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ ψ < 100 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,011	0,028	0,112	0,214	0,340	Versuchsreihe I Umgebungsgrößen statisch
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,011	0,029	0,128	0,243	0,394	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,011	0,032	0,145	0,276	0,451	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,011	0,036	0,162	0,310	0,514	
100 W/m ² < ψ ψ < 500 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,030	0,135	0,226	0,359	0,530	
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,033	0,149	0,249	0,398	0,596	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,035	0,162	0,273	0,441	0,667	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,038	0,177	0,300	0,486	0,746	
500 W/m ² < ψ ψ < 900 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,000	0,067	0,181	0,293	0,439	0,613	0,803	
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,000	0,070	0,192	0,311	0,469	0,664	0,885	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,000	0,075	0,203	0,330	0,501	0,718	0,973	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,000	0,081	0,216	0,349	0,534	0,773	1,065	
ψ < 900 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,044	0,132	0,240	0,364	0,499	0,661	0,853	
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,043	0,137	0,252	0,383	0,531	0,713	0,938	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,046	0,145	0,265	0,403	0,564	0,768	1,027	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,049	0,154	0,278	0,423	0,598	0,825	1,123	
0 W/m ² < ψ ψ < 100 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,010	0,040	0,120	0,220	0,350	Versuchsreihe II Umgebungsgrößen dynamisch
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,010	0,042	0,135	0,251	0,404	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,010	0,046	0,152	0,284	0,463	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,010	0,050	0,172	0,320	0,528	
100 W/m ² < ψ ψ < 500 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,031	0,131	0,221	0,351	0,520	
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,034	0,144	0,244	0,392	0,588	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,036	0,157	0,269	0,433	0,658	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,040	0,172	0,294	0,478	0,736	
500 W/m ² < ψ ψ < 900 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,036	0,086	0,180	0,302	0,428	0,583	0,773	
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,035	0,089	0,190	0,320	0,459	0,634	0,854	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,037	0,094	0,201	0,339	0,491	0,687	0,940	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,040	0,101	0,213	0,359	0,525	0,742	1,033	
ψ < 900 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,064	0,138	0,234	0,358	0,491	0,653	0,849	
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,064	0,143	0,245	0,378	0,523	0,707	0,933	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,067	0,150	0,257	0,398	0,557	0,762	1,023	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,071	0,158	0,269	0,419	0,591	0,819	1,119	
0 W/m ² < ψ ψ < 100 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,011	0,028	0,112	0,214	0,340	Versuchsreihe III Begrenztes Energiebudget
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,011	0,029	0,128	0,243	0,394	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,011	0,032	0,145	0,276	0,451	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,011	0,036	0,162	0,310	0,514	
100 W/m ² < ψ ψ < 500 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,030	0,135	0,226	0,359	0,530	
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,033	0,149	0,249	0,398	0,596	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,035	0,162	0,273	0,441	0,667	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,038	0,177	0,300	0,486	0,746	
500 W/m ² < ψ ψ < 900 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,000	0,067	0,181	0,293	0,439	0,613	0,803	
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,000	0,070	0,192	0,311	0,469	0,664	0,885	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,000	0,075	0,203	0,330	0,501	0,718	0,973	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,000	0,081	0,216	0,349	0,534	0,773	1,046	
ψ < 900 W/m ²	20 < ϕ ≤ 40	0,000	0,000	0,000	0,000	0,000	0,044	0,132	0,240	0,364	0,499	0,661	0,853	
	40 < ϕ ≤ 60	0,000	0,000	0,000	0,000	0,000	0,043	0,137	0,252	0,383	0,531	0,713	0,938	
	60 < ϕ ≤ 80	0,000	0,000	0,000	0,000	0,000	0,046	0,145	0,265	0,403	0,564	0,768	1,027	
	80 < ϕ ≤ 100	0,000	0,000	0,000	0,000	0,000	0,049	0,154	0,278	0,423	0,598	0,825	1,050	

Anhang A.8 Situationsanalyse - Auswertung des Energiebedarfs PTC

		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C				
0 W/m ² < ψ ψ < 100 W/m ²	20 < φ ≤ 40	5,07	4,50	3,82	3,16	2,51	1,87	1,26	0,70	0,29	0,07	0,07	0,07	Versuchsreihe I Umgebungsgrößen statisch			
	40 < φ ≤ 60	5,07	4,50	3,82	3,16	2,51	1,87	1,26	0,70	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	5,07	4,50	3,82	3,16	2,51	1,87	1,26	0,70	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	5,07	4,50	3,82	3,16	2,51	1,87	1,26	0,70	0,29	0,07	0,07	0,07				
100 W/m ² < ψ ψ < 500 W/m ²	20 < φ ≤ 40	4,53	3,97	3,29	2,63	1,97	1,34	0,73	0,29	0,29	0,07	0,07	0,07		Versuchsreihe II Umgebungsgrößen dynamisch		
	40 < φ ≤ 60	4,53	3,97	3,29	2,63	1,97	1,34	0,73	0,29	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	4,53	3,97	3,29	2,63	1,97	1,34	0,73	0,29	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	4,53	3,97	3,29	2,63	1,97	1,34	0,73	0,29	0,29	0,07	0,07	0,07				
500 W/m ² < ψ ψ < 900 W/m ²	20 < φ ≤ 40	3,68	3,12	2,44	1,77	1,12	0,49	0,29	0,29	0,29	0,07	0,07	0,07			Versuchsreihe III Begrenztes Energiebudget	
	40 < φ ≤ 60	3,68	3,12	2,44	1,77	1,12	0,49	0,29	0,29	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	3,68	3,12	2,44	1,77	1,12	0,49	0,29	0,29	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	3,68	3,12	2,44	1,77	1,12	0,49	0,29	0,29	0,29	0,07	0,07	0,07				
ψ < 900 W/m ²	20 < φ ≤ 40	3,25	2,69	2,01	1,35	0,70	0,32	0,29	0,29	0,29	0,07	0,07	0,07				Versuchsreihe III Begrenztes Energiebudget
	40 < φ ≤ 60	3,25	2,69	2,01	1,35	0,70	0,32	0,29	0,29	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	3,25	2,69	2,01	1,35	0,70	0,32	0,29	0,29	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	3,26	2,69	2,01	1,35	0,70	0,32	0,29	0,29	0,29	0,07	0,07	0,07				
0 W/m ² < ψ ψ < 100 W/m ²	20 < φ ≤ 40	5,05	4,50	3,82	3,16	2,50	1,87	1,25	0,69	0,29	0,07	0,07	0,07	Versuchsreihe III Begrenztes Energiebudget			
	40 < φ ≤ 60	5,05	4,50	3,82	3,16	2,50	1,87	1,25	0,69	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	5,05	4,50	3,82	3,16	2,50	1,87	1,25	0,69	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	5,05	4,50	3,82	3,16	2,50	1,87	1,25	0,69	0,29	0,07	0,07	0,07				
100 W/m ² < ψ ψ < 500 W/m ²	20 < φ ≤ 40	4,56	3,98	3,30	2,64	1,99	1,35	0,75	0,29	0,29	0,07	0,07	0,07		Versuchsreihe III Begrenztes Energiebudget		
	40 < φ ≤ 60	4,56	3,98	3,30	2,64	1,99	1,35	0,75	0,29	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	4,56	3,98	3,30	2,64	1,99	1,35	0,75	0,29	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	4,56	3,98	3,30	2,64	1,99	1,35	0,75	0,29	0,29	0,07	0,07	0,07				
500 W/m ² < ψ ψ < 900 W/m ²	20 < φ ≤ 40	3,62	3,06	2,38	1,72	1,07	0,63	0,35	0,29	0,29	0,07	0,07	0,07			Versuchsreihe III Begrenztes Energiebudget	
	40 < φ ≤ 60	3,62	3,06	2,38	1,72	1,07	0,63	0,35	0,29	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	3,62	3,06	2,38	1,72	1,07	0,63	0,35	0,29	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	3,62	3,06	2,38	1,72	1,07	0,63	0,35	0,29	0,29	0,07	0,07	0,07				
ψ < 900 W/m ²	20 < φ ≤ 40	3,14	2,60	1,92	1,25	0,71	0,43	0,30	0,29	0,29	0,07	0,07	0,07				Versuchsreihe III Begrenztes Energiebudget
	40 < φ ≤ 60	3,14	2,60	1,92	1,25	0,71	0,43	0,30	0,29	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	3,14	2,60	1,92	1,25	0,71	0,43	0,30	0,29	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	3,14	2,60	1,92	1,25	0,71	0,43	0,30	0,29	0,29	0,07	0,07	0,07				
0 W/m ² < ψ ψ < 100 W/m ²	20 < φ ≤ 40	1,13	1,13	1,13	1,13	1,13	1,12	1,12	0,70	0,29	0,07	0,07	0,07	Versuchsreihe III Begrenztes Energiebudget			
	40 < φ ≤ 60	1,13	1,13	1,13	1,13	1,13	1,12	1,12	0,70	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	1,13	1,13	1,13	1,13	1,13	1,12	1,12	0,70	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	1,13	1,13	1,13	1,13	1,13	1,12	1,12	0,70	0,29	0,07	0,07	0,07				
100 W/m ² < ψ ψ < 500 W/m ²	20 < φ ≤ 40	1,13	1,13	1,13	1,13	1,12	1,11	0,73	0,29	0,29	0,07	0,07	0,07		Versuchsreihe III Begrenztes Energiebudget		
	40 < φ ≤ 60	1,13	1,13	1,13	1,13	1,12	1,12	0,73	0,29	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	1,13	1,13	1,13	1,13	1,12	1,11	0,73	0,29	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	1,13	1,13	1,13	1,13	1,12	1,12	0,73	0,29	0,29	0,07	0,07	0,07				
500 W/m ² < ψ ψ < 900 W/m ²	20 < φ ≤ 40	1,13	1,13	1,13	1,12	1,11	0,49	0,29	0,29	0,29	0,07	0,07	0,07			Versuchsreihe III Begrenztes Energiebudget	
	40 < φ ≤ 60	1,13	1,13	1,13	1,13	1,11	0,49	0,29	0,29	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	1,13	1,13	1,13	1,12	1,11	0,49	0,29	0,29	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	1,13	1,13	1,13	1,12	1,11	0,49	0,29	0,29	0,29	0,07	0,07	0,07				
ψ < 900 W/m ²	20 < φ ≤ 40	1,13	1,13	1,13	1,12	0,70	0,32	0,29	0,29	0,29	0,07	0,07	0,07				Versuchsreihe III Begrenztes Energiebudget
	40 < φ ≤ 60	1,13	1,13	1,13	1,12	0,70	0,32	0,29	0,29	0,29	0,07	0,07	0,07				
	60 < φ ≤ 80	1,13	1,13	1,13	1,12	0,70	0,32	0,29	0,29	0,29	0,07	0,07	0,07				
	80 < φ ≤ 100	1,13	1,13	1,13	1,12	0,70	0,32	0,29	0,29	0,29	0,07	0,07	0,07				

Anhang A.9 Situationsanalyse - Auswertung des Gesamtenergiebedarfs

		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C			
0 W/m ² < ψ $\psi < 100$ W/m ²	20 < $\phi \leq 40$	5,07	4,50	3,82	3,16	2,51	1,87	1,26	0,71	0,31	0,18	0,28	0,41	Versuchsreihe I Umgebungsgrößen statisch		
	40 < $\phi \leq 60$	5,07	4,50	3,82	3,16	2,51	1,87	1,26	0,71	0,32	0,20	0,31	0,46			
	60 < $\phi \leq 80$	5,07	4,50	3,82	3,16	2,51	1,87	1,26	0,71	0,32	0,21	0,35	0,52			
	80 < $\phi \leq 100$	5,07	4,50	3,82	3,16	2,51	1,87	1,26	0,71	0,32	0,23	0,38	0,58			
100 W/m ² < ψ $\psi < 500$ W/m ²	20 < $\phi \leq 40$	4,53	3,97	3,29	2,63	1,97	1,34	0,73	0,32	0,42	0,30	0,43	0,60		Versuchsreihe II Umgebungsgrößen dynamisch	
	40 < $\phi \leq 60$	4,53	3,97	3,29	2,63	1,97	1,34	0,73	0,32	0,43	0,32	0,47	0,67			
	60 < $\phi \leq 80$	4,53	3,97	3,29	2,63	1,97	1,34	0,73	0,32	0,45	0,34	0,51	0,74			
	80 < $\phi \leq 100$	4,53	3,97	3,29	2,63	1,97	1,34	0,73	0,32	0,46	0,37	0,56	0,82			
500 W/m ² < ψ $\psi < 900$ W/m ²	20 < $\phi \leq 40$	3,68	3,12	2,44	1,77	1,12	0,49	0,36	0,47	0,58	0,51	0,68	0,87			Versuchsreihe III Begrenztes Energiebudget
	40 < $\phi \leq 60$	3,68	3,12	2,44	1,77	1,12	0,49	0,36	0,48	0,60	0,54	0,73	0,96			
	60 < $\phi \leq 80$	3,68	3,12	2,44	1,77	1,12	0,49	0,36	0,49	0,62	0,57	0,79	1,04			
	80 < $\phi \leq 100$	3,68	3,12	2,44	1,77	1,12	0,49	0,37	0,50	0,64	0,60	0,84	1,14			
$\psi < 900$ W/m ²	20 < $\phi \leq 40$	3,25	2,69	2,01	1,35	0,70	0,37	0,42	0,53	0,65	0,57	0,73	0,92	Versuchsreihe III Begrenztes Energiebudget		
	40 < $\phi \leq 60$	3,25	2,69	2,01	1,35	0,70	0,37	0,42	0,54	0,67	0,60	0,78	1,01			
	60 < $\phi \leq 80$	3,25	2,69	2,01	1,35	0,70	0,37	0,43	0,55	0,69	0,63	0,84	1,10			
	80 < $\phi \leq 100$	3,26	2,69	2,01	1,35	0,70	0,37	0,44	0,56	0,71	0,67	0,90	1,19			
0 W/m ² < ψ $\psi < 100$ W/m ²	20 < $\phi \leq 40$	5,05	4,50	3,82	3,16	2,50	1,87	1,25	0,70	0,33	0,19	0,29	0,42		Versuchsreihe III Begrenztes Energiebudget	
	40 < $\phi \leq 60$	5,05	4,50	3,82	3,16	2,50	1,87	1,25	0,70	0,33	0,21	0,32	0,47			
	60 < $\phi \leq 80$	5,05	4,50	3,82	3,16	2,50	1,87	1,25	0,70	0,33	0,22	0,35	0,53			
	80 < $\phi \leq 100$	5,05	4,50	3,82	3,16	2,50	1,87	1,25	0,70	0,34	0,24	0,39	0,60			
100 W/m ² < ψ $\psi < 500$ W/m ²	20 < $\phi \leq 40$	4,56	3,98	3,30	2,64	1,99	1,35	0,75	0,32	0,42	0,29	0,42	0,59			Versuchsreihe III Begrenztes Energiebudget
	40 < $\phi \leq 60$	4,56	3,98	3,30	2,64	1,99	1,35	0,75	0,32	0,43	0,31	0,46	0,66			
	60 < $\phi \leq 80$	4,56	3,98	3,30	2,64	1,99	1,35	0,75	0,32	0,44	0,34	0,50	0,73			
	80 < $\phi \leq 100$	4,56	3,98	3,30	2,64	1,99	1,35	0,75	0,33	0,46	0,36	0,55	0,81			
500 W/m ² < ψ $\psi < 900$ W/m ²	20 < $\phi \leq 40$	3,62	3,06	2,38	1,72	1,07	0,67	0,43	0,47	0,59	0,50	0,65	0,84	Versuchsreihe III Begrenztes Energiebudget		
	40 < $\phi \leq 60$	3,62	3,06	2,38	1,72	1,07	0,67	0,43	0,48	0,61	0,53	0,70	0,92			
	60 < $\phi \leq 80$	3,62	3,06	2,38	1,72	1,07	0,67	0,44	0,49	0,63	0,56	0,76	1,01			
	80 < $\phi \leq 100$	3,62	3,06	2,38	1,72	1,07	0,68	0,45	0,50	0,65	0,59	0,81	1,10			
$\psi < 900$ W/m ²	20 < $\phi \leq 40$	3,14	2,60	1,92	1,25	0,71	0,49	0,44	0,52	0,64	0,56	0,72	0,92		Versuchsreihe III Begrenztes Energiebudget	
	40 < $\phi \leq 60$	3,14	2,60	1,92	1,25	0,71	0,49	0,44	0,53	0,66	0,59	0,78	1,00			
	60 < $\phi \leq 80$	3,14	2,60	1,92	1,25	0,71	0,50	0,45	0,54	0,68	0,63	0,83	1,09			
	80 < $\phi \leq 100$	3,14	2,60	1,92	1,25	0,71	0,50	0,46	0,56	0,70	0,66	0,89	1,19			
0 W/m ² < ψ $\psi < 100$ W/m ²	20 < $\phi \leq 40$	1,13	1,13	1,13	1,13	1,13	1,12	1,12	0,71	0,31	0,18	0,28	0,41			Versuchsreihe III Begrenztes Energiebudget
	40 < $\phi \leq 60$	1,13	1,13	1,13	1,13	1,13	1,12	1,12	0,71	0,32	0,20	0,31	0,46			
	60 < $\phi \leq 80$	1,13	1,13	1,13	1,13	1,13	1,12	1,12	0,71	0,32	0,21	0,35	0,52			
	80 < $\phi \leq 100$	1,13	1,13	1,13	1,13	1,13	1,12	1,12	0,71	0,32	0,23	0,38	0,58			
100 W/m ² < ψ $\psi < 500$ W/m ²	20 < $\phi \leq 40$	1,13	1,13	1,13	1,13	1,12	1,11	0,73	0,32	0,42	0,30	0,43	0,60	Versuchsreihe III Begrenztes Energiebudget		
	40 < $\phi \leq 60$	1,13	1,13	1,13	1,13	1,12	1,12	0,73	0,32	0,43	0,32	0,47	0,67			
	60 < $\phi \leq 80$	1,13	1,13	1,13	1,13	1,12	1,11	0,73	0,32	0,45	0,34	0,51	0,74			
	80 < $\phi \leq 100$	1,13	1,13	1,13	1,13	1,12	1,12	0,73	0,32	0,46	0,37	0,56	0,82			
500 W/m ² < ψ $\psi < 900$ W/m ²	20 < $\phi \leq 40$	1,13	1,13	1,13	1,12	1,11	0,49	0,36	0,47	0,58	0,51	0,68	0,87		Versuchsreihe III Begrenztes Energiebudget	
	40 < $\phi \leq 60$	1,13	1,13	1,13	1,13	1,11	0,49	0,36	0,48	0,60	0,54	0,73	0,96			
	60 < $\phi \leq 80$	1,13	1,13	1,13	1,12	1,11	0,49	0,36	0,49	0,62	0,57	0,79	1,04			
	80 < $\phi \leq 100$	1,13	1,13	1,13	1,12	1,11	0,49	0,37	0,50	0,64	0,60	0,84	1,12			
$\psi < 900$ W/m ²	20 < $\phi \leq 40$	1,13	1,13	1,13	1,12	0,70	0,37	0,42	0,53	0,65	0,57	0,73	0,92			Versuchsreihe III Begrenztes Energiebudget
	40 < $\phi \leq 60$	1,13	1,13	1,13	1,12	0,70	0,37	0,42	0,54	0,67	0,60	0,78	1,01			
	60 < $\phi \leq 80$	1,13	1,13	1,13	1,12	0,70	0,37	0,43	0,55	0,69	0,63	0,84	1,10			
	80 < $\phi \leq 100$	1,13	1,13	1,13	1,12	0,70	0,37	0,44	0,56	0,71	0,67	0,90	1,12			

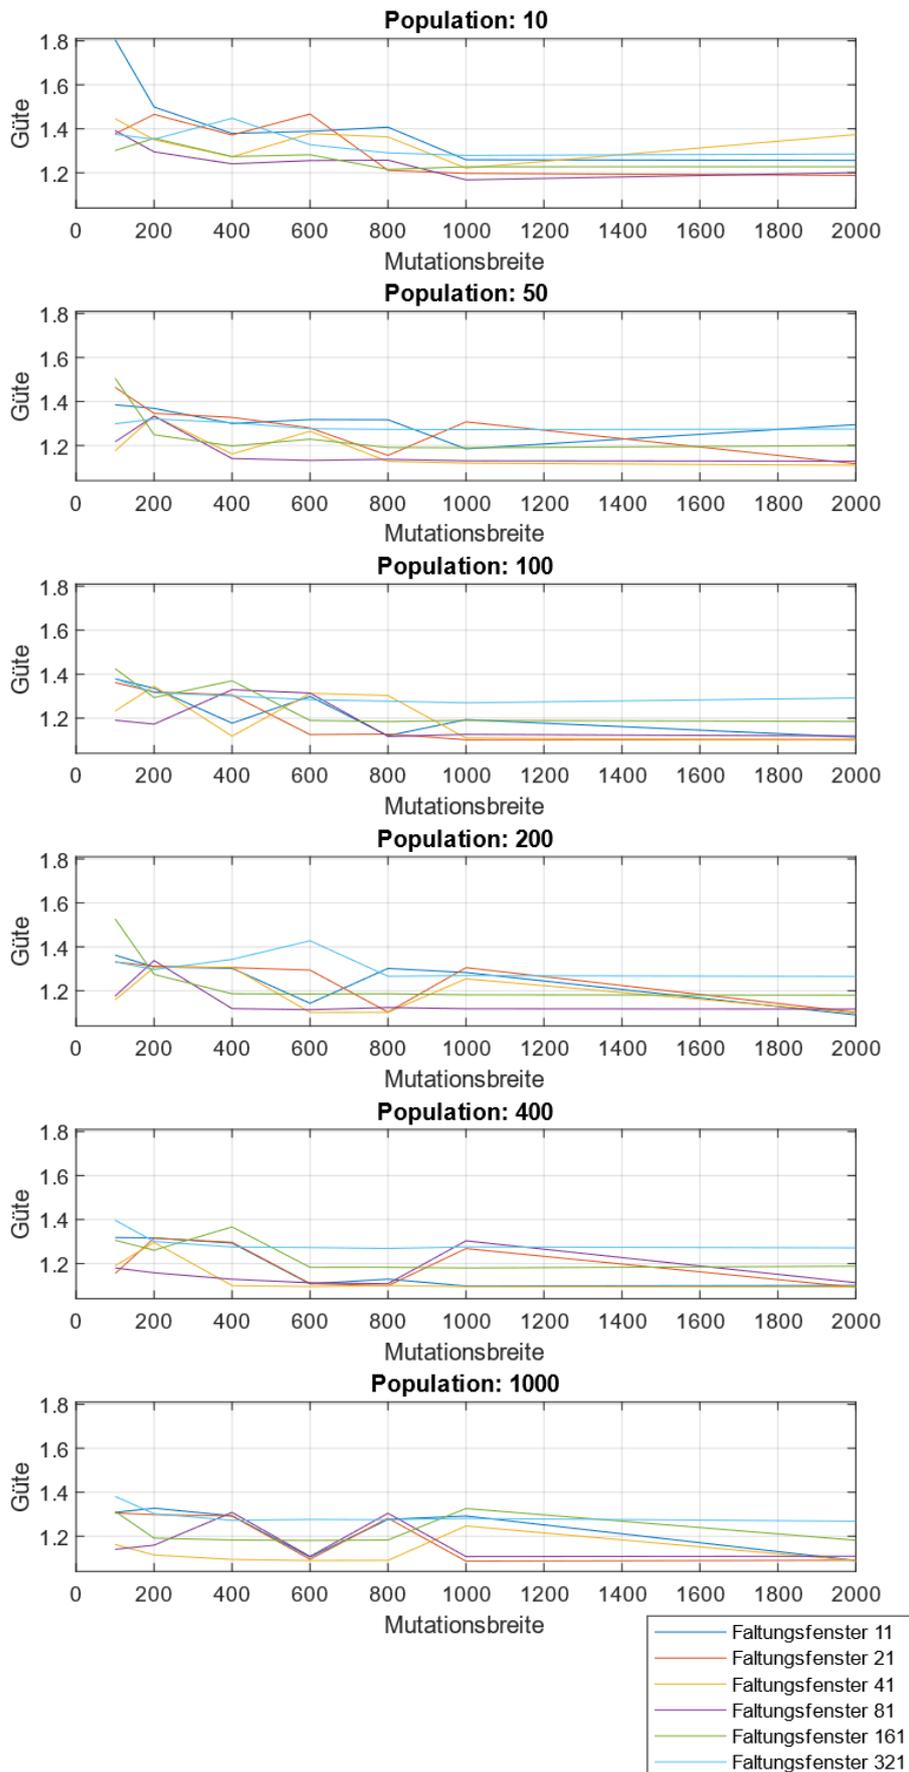
Anhang A.10 Ausschnitt des Datenmodell zur Ablage der Trainingsdaten zur Störgrößenprognose

Feuchte_learn_Input
+ FLID: int
+ FID: int
+ SID: int
+ Referenz_offset: double
+ Startwert_Feucht_Messung: double
+ Wetterabfrage: double
+ Prognose_1: double
+ Prognose_2: double
+ Zeitdiff_Messung: double
+ Zeitdiff_Wetterabfrage: double
+ Zeitdiff_Prognose_1: double
+ Zeitdiff_Prognose_2: double
+ Mess_Feuchte: double

Strahlung_learn_Input
+ SLID: int
+ FID: int
+ SID: int
+ Azimut: double
+ Sonnenhöhe: double
+ Wetterabfrage: double
+ Prognose_1: double
+ Prognose_2: double
+ Zeitdiff_Messstart: double
+ Zeitdiff_Openweather: double
+ Zeitdiff_Openweather_forecast1: double
+ Richtung: double
+ Strahlung: double

Temp_learn_Input
+ TLID: int
+ FID: int
+ SID: int
+ Referenz_offset: double
+ Startwert_Temp_Messung: double
+ Wetterabfrage: double
+ Prognose_1: double
+ Prognose_2: double
+ Zeitdiff_Messung: double
+ Zeitdiff_Wetterabfrage: double
+ Zeitdiff_Prognose_1: double
+ Zeitdiff_Prognose_2: double
+ Mess_Temp: double

Anhang A.11 Versuch zur Ermittlung von Evolutionsparametern



Anhang A.12 Bewertung der Optimierungsziele – Auswertung Versuchsreihe 2

Metrik 1		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ	20 < φ ≤ 40	0,57	0,49	0,33	0,21	0,13	0,06	0,02	0,07	0,10	0,16	0,18	0,21	Versuchsreihe II Umgebungsgrößen dynamisch
	40 < φ ≤ 60	0,58	0,50	0,33	0,21	0,13	0,05	0,02	0,07	0,10	0,18	0,18	0,21	
	60 < φ ≤ 80	0,58	0,51	0,34	0,21	0,12	0,05	0,02	0,07	0,10	0,16	0,20	0,28	
	80 < φ ≤ 100	0,59	0,52	0,35	0,22	0,13	0,06	0,03	0,07	0,12	0,18	0,26	0,40	
100 W/m ² < ψ	20 < φ ≤ 40	0,56	0,47	0,31	0,19	0,12	0,06	0,04	0,09	0,12	0,24	0,16	0,18	
	40 < φ ≤ 60	0,57	0,47	0,31	0,19	0,12	0,06	0,03	0,09	0,12	0,24	0,18	0,16	
	60 < φ ≤ 80	0,57	0,48	0,31	0,19	0,11	0,06	0,03	0,09	0,11	0,23	0,18	0,17	
	80 < φ ≤ 100	0,58	0,48	0,32	0,20	0,10	0,06	0,03	0,10	0,11	0,25	0,18	0,22	
500 W/m ² < ψ	20 < φ ≤ 40	0,57	0,50	0,33	0,22	0,16	0,11	0,11	0,16	0,47	0,91	1,56	2,20	
	40 < φ ≤ 60	0,57	0,50	0,33	0,21	0,15	0,11	0,12	0,15	0,47	1,09	1,57	2,23	
	60 < φ ≤ 80	0,57	0,50	0,33	0,22	0,15	0,10	0,10	0,16	0,45	1,13	1,58	2,26	
	80 < φ ≤ 100	0,57	0,50	0,34	0,22	0,14	0,10	0,09	0,16	0,47	1,18	1,58	2,29	
ψ < 900 W/m ²	20 < φ ≤ 40	0,57	0,55	0,37	0,24	0,78	0,14	0,12	0,61	1,39	2,10	2,81	3,58	
	40 < φ ≤ 60	0,57	0,55	0,37	0,24	0,78	0,12	0,12	0,62	1,36	2,23	2,83	3,60	
	60 < φ ≤ 80	0,58	0,56	0,38	0,24	0,78	0,15	0,13	0,58	1,31	2,22	2,83	3,62	
	80 < φ ≤ 100	0,58	0,56	0,38	0,25	0,77	0,12	0,11	0,57	1,31	2,17	2,85	3,63	
Metrik 7		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ	20 < φ ≤ 40	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,04	0,12	0,25	0,39	Versuchsreihe II Umgebungsgrößen dynamisch
	40 < φ ≤ 60	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,13	0,28	0,44	
	60 < φ ≤ 80	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,16	0,31	0,49	
	80 < φ ≤ 100	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,05	0,19	0,33	0,50	
100 W/m ² < ψ	20 < φ ≤ 40	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,14	0,22	0,38	0,55	
	40 < φ ≤ 60	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,14	0,25	0,42	0,63	
	60 < φ ≤ 80	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,14	0,28	0,46	0,69	
	80 < φ ≤ 100	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,16	0,31	0,50	0,77	
500 W/m ² < ψ	20 < φ ≤ 40	0,00	0,00	0,00	0,00	0,00	0,04	0,09	0,19	0,31	0,44	0,60	0,80	
	40 < φ ≤ 60	0,00	0,00	0,00	0,00	0,00	0,04	0,10	0,20	0,32	0,45	0,65	0,89	
	60 < φ ≤ 80	0,00	0,00	0,00	0,00	0,00	0,04	0,10	0,20	0,34	0,48	0,71	0,97	
	80 < φ ≤ 100	0,00	0,00	0,00	0,00	0,00	0,04	0,10	0,21	0,36	0,52	0,76	1,06	
ψ < 900 W/m ²	20 < φ ≤ 40	0,00	0,00	0,00	0,00	0,00	0,07	0,14	0,23	0,37	0,49	0,67	0,86	
	40 < φ ≤ 60	0,00	0,00	0,00	0,00	0,00	0,07	0,15	0,25	0,38	0,52	0,72	0,95	
	60 < φ ≤ 80	0,00	0,00	0,00	0,00	0,00	0,08	0,15	0,26	0,40	0,55	0,78	1,04	
	80 < φ ≤ 100	0,00	0,00	0,00	0,00	0,00	0,08	0,16	0,27	0,42	0,59	0,83	1,14	
Metrik 8		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ	20 < φ ≤ 40	5,04	4,50	3,82	3,15	2,52	1,88	1,25	0,68	0,27	0,27	0,06	0,06	Versuchsreihe II Umgebungsgrößen dynamisch
	40 < φ ≤ 60	5,05	4,51	3,82	3,16	2,53	1,87	1,25	0,67	0,27	0,27	0,06	0,05	
	60 < φ ≤ 80	5,06	4,51	3,84	3,17	2,52	1,87	1,25	0,68	0,27	0,25	0,05	0,03	
	80 < φ ≤ 100	5,06	4,52	3,84	3,18	2,53	1,87	1,25	0,68	0,26	0,24	0,01	0,00	
100 W/m ² < ψ	20 < φ ≤ 40	4,55	3,98	3,30	2,62	2,00	1,36	0,74	0,29	0,27	0,20	0,06	0,06	
	40 < φ ≤ 60	4,56	3,98	3,30	2,63	2,01	1,36	0,74	0,29	0,29	0,22	0,06	0,05	
	60 < φ ≤ 80	4,56	3,98	3,31	2,65	2,01	1,35	0,74	0,29	0,28	0,16	0,05	0,05	
	80 < φ ≤ 100	4,57	3,99	3,32	2,66	2,01	1,35	0,74	0,29	0,26	0,21	0,04	0,04	
500 W/m ² < ψ	20 < φ ≤ 40	3,59	3,04	2,36	1,68	1,07	0,64	0,38	0,29	0,28	0,07	0,06	0,06	
	40 < φ ≤ 60	3,59	3,04	2,36	1,69	1,08	0,64	0,37	0,29	0,28	0,23	0,06	0,06	
	60 < φ ≤ 80	3,60	3,04	2,37	1,71	1,08	0,62	0,36	0,29	0,27	0,23	0,06	0,06	
	80 < φ ≤ 100	3,60	3,05	2,38	1,72	1,07	0,62	0,36	0,29	0,29	0,23	0,06	0,06	
ψ < 900 W/m ²	20 < φ ≤ 40	3,14	2,60	1,92	1,24	0,67	0,45	0,32	0,27	0,27	0,20	0,07	0,06	
	40 < φ ≤ 60	3,15	2,60	1,91	1,23	0,67	0,46	0,29	0,29	0,29	0,30	0,06	0,06	
	60 < φ ≤ 80	3,15	2,60	1,91	1,25	0,68	0,46	0,28	0,29	0,27	0,30	0,07	0,06	
	80 < φ ≤ 100	3,16	2,61	1,93	1,26	0,67	0,46	0,29	0,29	0,28	0,29	0,06	0,06	
Metrik 9		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ	20 < φ ≤ 40	5,04	4,50	3,82	3,15	2,52	1,88	1,25	0,69	0,31	0,38	0,31	0,45	Versuchsreihe II Umgebungsgrößen dynamisch
	40 < φ ≤ 60	5,05	4,51	3,82	3,16	2,53	1,87	1,25	0,68	0,31	0,40	0,33	0,49	
	60 < φ ≤ 80	5,06	4,51	3,84	3,17	2,53	1,87	1,25	0,68	0,31	0,41	0,35	0,52	
	80 < φ ≤ 100	5,06	4,52	3,84	3,18	2,53	1,87	1,25	0,69	0,31	0,42	0,34	0,42	
100 W/m ² < ψ	20 < φ ≤ 40	4,55	3,98	3,30	2,62	2,00	1,36	0,74	0,33	0,41	0,42	0,44	0,61	
	40 < φ ≤ 60	4,56	3,98	3,30	2,63	2,01	1,36	0,74	0,32	0,42	0,47	0,48	0,68	
	60 < φ ≤ 80	4,56	3,98	3,31	2,65	2,02	1,35	0,74	0,33	0,42	0,45	0,51	0,74	
	80 < φ ≤ 100	4,57	3,99	3,32	2,66	2,01	1,35	0,74	0,33	0,42	0,52	0,55	0,81	
500 W/m ² < ψ	20 < φ ≤ 40	3,59	3,04	2,36	1,68	1,08	0,68	0,46	0,47	0,60	0,51	0,67	0,86	
	40 < φ ≤ 60	3,59	3,04	2,36	1,69	1,08	0,68	0,47	0,48	0,60	0,68	0,71	0,95	
	60 < φ ≤ 80	3,60	3,04	2,37	1,71	1,08	0,66	0,46	0,49	0,61	0,71	0,77	1,03	
	80 < φ ≤ 100	3,60	3,05	2,38	1,72	1,07	0,66	0,46	0,50	0,65	0,75	0,82	1,12	
ψ < 900 W/m ²	20 < φ ≤ 40	3,14	2,60	1,92	1,24	0,67	0,52	0,46	0,50	0,64	0,70	0,73	0,92	
	40 < φ ≤ 60	3,15	2,60	1,91	1,23	0,67	0,54	0,44	0,54	0,67	0,82	0,78	1,02	
	60 < φ ≤ 80	3,15	2,60	1,91	1,25	0,68	0,54	0,43	0,55	0,67	0,85	0,84	1,11	
	80 < φ ≤ 100	3,16	2,61	1,93	1,26	0,67	0,54	0,45	0,56	0,70	0,88	0,90	1,21	

Anhang A.13 Bewertung der Optimierungsziele – Auswertung Versuchsreihe 3

Metrik 1		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ ψ < 100 W/m ²	20 < φ ≤ 40	18,74	16,09	12,84	9,71	6,52	3,47	0,73	0,06	0,10	0,19	0,17	0,22	Versuchsreihe III Begrenztes Energiebudget
	40 < φ ≤ 60	18,52	15,92	12,79	9,61	6,47	3,54	0,79	0,06	0,10	0,17	0,18	0,22	
	60 < φ ≤ 80	18,63	16,01	12,84	9,68	6,39	3,43	0,69	0,06	0,10	0,17	0,18	0,27	
	80 < φ ≤ 100	18,55	16,02	12,87	9,55	6,40	3,50	0,71	0,07	0,11	0,16	0,24	0,40	
100 W/m ² < ψ ψ < 500 W/m ²	20 < φ ≤ 40	16,34	13,65	10,35	7,16	4,09	1,06	0,03	0,12	0,14	0,25	0,16	0,16	
	40 < φ ≤ 60	16,31	13,59	10,32	7,18	4,12	1,08	0,03	0,12	0,12	0,24	0,17	0,16	
	60 < φ ≤ 80	16,33	13,65	10,30	7,25	4,04	1,09	0,03	0,13	0,12	0,24	0,17	0,17	
	80 < φ ≤ 100	16,33	13,68	10,40	7,17	3,98	1,05	0,03	0,14	0,13	0,25	0,17	0,21	
500 W/m ² < ψ ψ < 900 W/m ²	20 < φ ≤ 40	12,25	9,62	6,41	3,17	0,25	0,06	0,09	0,13	0,14	0,15	0,61	1,33	
	40 < φ ≤ 60	12,15	9,66	6,38	3,25	0,24	0,06	0,09	0,14	0,15	0,15	0,63	1,36	
	60 < φ ≤ 80	12,22	9,72	6,47	3,22	0,22	0,06	0,09	0,14	0,14	0,15	0,62	1,34	
	80 < φ ≤ 100	12,17	9,72	6,50	3,29	0,19	0,07	0,10	0,15	0,14	0,25	0,62	1,55	
ψ < 900 W/m ²	20 < φ ≤ 40	10,31	7,60	4,32	1,29	0,11	0,16	0,10	0,14	0,30	1,01	1,92	2,71	
	40 < φ ≤ 60	10,34	7,66	4,38	1,31	0,10	0,09	0,10	0,14	0,29	1,02	1,91	2,69	
	60 < φ ≤ 80	10,36	7,73	4,41	1,28	0,09	0,10	0,10	0,16	0,29	0,99	1,91	2,66	
	80 < φ ≤ 100	10,44	7,75	4,40	1,35	0,08	0,09	0,10	0,14	0,30	0,98	1,89	3,11	
Metrik 3		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ ψ < 100 W/m ²	20 < φ ≤ 40	6,90	5,12	4,54	3,26	1,41	0,00	0,00	0,00	0,00	0,00	0,00	0,00	Versuchsreihe III Begrenztes Energiebudget
	40 < φ ≤ 60	6,72	5,06	3,36	1,95	1,12	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	60 < φ ≤ 80	6,92	5,38	3,20	2,08	1,18	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	80 < φ ≤ 100	6,67	4,86	3,07	2,53	1,19	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
100 W/m ² < ψ ψ < 500 W/m ²	20 < φ ≤ 40	4,99	4,69	3,05	1,34	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	40 < φ ≤ 60	4,88	3,77	2,26	1,23	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	60 < φ ≤ 80	4,74	3,06	2,84	1,06	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	80 < φ ≤ 100	4,77	3,26	2,26	0,93	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
500 W/m ² < ψ ψ < 900 W/m ²	20 < φ ≤ 40	1,27	1,57	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	40 < φ ≤ 60	2,39	1,34	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	60 < φ ≤ 80	2,93	1,17	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	80 < φ ≤ 100	2,82	1,28	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
ψ < 900 W/m ²	20 < φ ≤ 40	1,58	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	40 < φ ≤ 60	1,34	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	60 < φ ≤ 80	1,46	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
	80 < φ ≤ 100	1,48	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
Metrik 9		-25°C- -20°C	-20°C- -15°C	-15°C- -10°C	-10°C- -5°C	-5°C- 0°C	0°C- 5°C	5°C- 10°C	10°C- 15°C	15°C- 20°C	20°C- 25°C	25°C- 30°C	30°C- 35°C	
0 W/m ² < ψ ψ < 100 W/m ²	20 < φ ≤ 40	1,11	1,11	1,11	1,10	1,10	1,10	1,10	0,68	0,30	0,33	0,30	0,43	Versuchsreihe III Begrenztes Energiebudget
	40 < φ ≤ 60	1,11	1,11	1,11	1,10	1,10	1,10	1,10	0,69	0,29	0,35	0,32	0,48	
	60 < φ ≤ 80	1,10	1,11	1,11	1,10	1,10	1,10	1,10	0,69	0,29	0,37	0,35	0,50	
	80 < φ ≤ 100	1,10	1,11	1,10	1,10	1,10	1,10	1,10	0,69	0,30	0,37	0,33	0,40	
100 W/m ² < ψ ψ < 500 W/m ²	20 < φ ≤ 40	1,11	1,11	1,10	1,10	1,10	1,10	0,72	0,32	0,42	0,41	0,45	0,62	
	40 < φ ≤ 60	1,11	1,11	1,10	1,10	1,10	1,10	0,73	0,32	0,42	0,45	0,48	0,69	
	60 < φ ≤ 80	1,11	1,10	1,10	1,10	1,10	1,10	0,73	0,32	0,42	0,48	0,51	0,75	
	80 < φ ≤ 100	1,11	1,10	1,10	1,10	1,10	1,10	0,73	0,32	0,45	0,50	0,55	0,82	
500 W/m ² < ψ ψ < 900 W/m ²	20 < φ ≤ 40	1,10	1,10	1,10	1,10	1,10	0,49	0,35	0,46	0,59	0,52	0,69	0,88	
	40 < φ ≤ 60	1,10	1,10	1,10	1,10	1,10	0,49	0,36	0,47	0,60	0,55	0,74	0,97	
	60 < φ ≤ 80	1,10	1,10	1,10	1,10	1,10	0,50	0,36	0,48	0,60	0,55	0,80	1,05	
	80 < φ ≤ 100	1,10	1,10	1,10	1,10	1,10	0,50	0,37	0,49	0,60	0,60	0,85	1,10	
ψ < 900 W/m ²	20 < φ ≤ 40	1,10	1,10	1,10	1,10	0,72	0,36	0,40	0,52	0,66	0,55	0,74	0,93	
	40 < φ ≤ 60	1,10	1,10	1,10	1,10	0,72	0,37	0,42	0,53	0,69	0,59	0,80	1,03	
	60 < φ ≤ 80	1,10	1,10	1,10	1,10	0,71	0,37	0,42	0,54	0,72	0,61	0,85	1,10	
	80 < φ ≤ 100	1,10	1,10	1,10	1,10	0,71	0,36	0,43	0,55	0,73	0,64	0,91	1,10	