Verbundvorhaben PHyMoS: Proper Hybrid Models for Smarter Vehicles
Schlussbericht zum Teilvorhaben der TLK-Thermo GmbH

Henrik Schatz, Andreas Varchmin, Philipp Ebeling

26. Februar 2025

Projektzeitraum:	01.03.2021 - 31.08.2024
Berichtszeitraum:	01.03.2021 - 31.08.2024
Förderkennzeichen:	19I20022C
Zuwendungsempfänger:	TLK-Thermo GmbH

Finanziert von der Europäischen Union
NextGenerationEU

Gefördert durch:

Bundesministerium für Wirtschaft und Klimaschutz

aufgrund eines Beschlusses des Deutschen Bundestages

Inhaltsverzeichnis

I Kurze Darstellung **3**

1 Aufgabenstellung **3**

2 Voraussetzungen **3**

3 Planung und Ablauf des Vorhabens **3**

4 Wissenschaftlicher und technischer Stand **4**

5 Zusammenarbeit mit anderen Stellen **4**

II Eingehende Darstellung **5**

1 Verwendung der Zuwendung und des erzielten Ergebnisses **5**
1.1 AP5 Werkzeugkette für Thermomanagementsysteme 5
1.2 AP6.4 Schnelles Proper Model für die Wärmepumpe eines Thermomanagements 9
1.3 AP6.5 ROM eines 3D-Batteriesystems 19

2 Relevante Positionen des zahlenmäßigen Nachweises **19**

3 Notwendigkeit und Angemessenheit der geleisteten Arbeit **20**

4 Voraussichtlicher Nutzen und Verwertbarkeit der Ergebnisse **20**

5 Fortschritt bei anderen Stellen **22**

6 Erfolgte und geplante Veröffentlichungen der Ergebnisse **22**

III Literaturverzeichnis **24**

Teil I
Kurze Darstellung

1 Aufgabenstellung

Das Ziel des Verbundprojekts PHyMoS war es, Modelle von Fahrzeugen für verschiedene Anwendungen zu generieren, die sich hinsichtlich der Anforderungen von Abbildungsgenauigkeit („Genauigkeit) und kurzer Laufzeit („Performanz“) unterscheiden. Ebenso sollten Software-Werkzeuge zur Generierung dieser entwickelt werden. In PHyMoS werden diese Modelle „Proper Models“ genannt und basieren auf einer Kombination von Methoden des maschinellen Lernens und physikalischen Modellen. Im Teilvorhaben „Werkzeugkette für Thermomanagementsysteme“ der TLK-Thermo GmbH (TLK) war die Zielstellung, KI und Modellreduktionsmethoden zu verwenden, um verschiedene Prozesse zur Optimierung des Thermomanagements von Elektrofahrzeugen zu entwickeln. Konkrete Ziele waren:

- Zusammenstellung von Anforderungen und Anwendungsszenarien für KI-Methoden für maschinelles Lernen sowie Modellreduktionsmethoden
- Schnelle und robuste neuartige Simulationsmodelle für verschiedene Hardware-Ebenen
- Verfahren zur Erstellung der Modelle in der Automatisierungsplattform MoBA Automation

2 Voraussetzungen

Zur Erreichung der gesteckten Ziele wurde auf fundierten Kenntnissen auf den Gebieten der Simulationstechnik, des maschinellen Lernens sowie der Modellierung thermischer Systeme aufgebaut. Grundlage für das Vorhaben waren unter anderem die Modelica-Komponentenbibliothek TIL für thermische Systeme [9], Analysemethoden für hohe Robustheit der nichtlinearen und anspruchsvoll zu lösenden thermischen Simulationsmodelle, Expertise in der Verwendung von Modellen auf verschiedenen Hardware-Ebenen, sowie High-Speed-Stoffdatenmodelle [17]. Durch die TLK-Software MoBA Automation [8] stand eine spzeialisierte Anwendung zur Automatisierung von Entwicklungsprozessen bereit. Diese bildete die Basis für eine hohe Anzahl von Simulationen und Auswertungen, sowie die Erstellung neuronaler Netze.

3 Planung und Ablauf des Vorhabens

Das Förderprojekt PHyMoS wurde im Jahr 2020 und für einen Zeitraum von drei Jahren geplant. Die Projektlaufzeit wurde kostenneutral um sechs Monate

verlängert. TLK war an den Arbeitspaketen 1 bis 6 beteiligt. In AP1 und AP2 hat TLK Anforderungen und Anwendungsszenarien bzgl. des Thermomanagements von Elektrofahrzeugen eingebracht. In AP3 und AP4 hat TLK beratend mitgewirkt, indem anwendungsspezifisches Wissen geteilt wurde. Schwerpunkt der Aktivitäten von TLK lagen auf AP5 und AP6. In AP6 wurden unterschiedliche KI-Methoden für maschinelles Lernen angewendet, um schnelle und robuste neuartige Simulationsmodelle für verschiedene Hardware-Ebenen zu generieren. In AP5 wurden die Verfahren zur Erstellung der Modelle und zur Visualisierung in der Automatisierungsplattform MoBA Automation abgebildet mit Anbindung an die Visualisierungssoftware DaVE.

4 Wissenschaftlicher und technischer Stand

Bei der Anwendung auf Thermomanagementsysteme und ihre Regelung konnte auf diversen bereits abgeschlossenen Forschungsvorhaben und Kundenprojekten aufgebaut werden [12, 15, 18]. Flexible Regelungen und Optimierungsverfahren für Kältekreisläufe wurden in VEOTOP [20] entworfen. In Reflex Thermo [19] wurden modellbasierte Regelungen für Thermomanagementsysteme entwickelt. Simulationsmodelle zur Berechnung von Wärmeübertrager-Vereisung wurden von TLK mit Partnern entwickelt und während der Projektlauzeit in [21] veröffentlicht.

Modellreduktionsverfahren zur Abbildung lokaler Effekte in Batteriesystemen wurden in DIMOBA erforscht [6].

Auch bei der Erzeugung datenbasierter Modelle waren Vorarbeiten vorhanden. Werkzeuge zur Erstellung neuronaler Netze für stationäre Problemstellungen standen in der TLK-Software MoBA Automation durch AUTOGEN [5] zur Verfügung. Zusätzlich wurde auf den bestehenden Python-Bibliotheken tensorflow und scikit-learn aufgebaut. Zur Lösung dynamischer Problemstellungen wurde auf den Python-Bibliotheken pytorch, torchdiffeq, jax, equinox und diffrax aufgebaut.

Zur Lösung von Optimalsteuerungen konnte auf der Open-Source-Software CasADi aufgebaut werden [1].

Das Modellaustauschformat FMI [2] wurde sowohl für Simulationsstudien als auch für Analysen und Bewertungen verwendet.

Die verwendete Fachliteratur ist an den jeweiligen Stellen in der Ergebnisdarstellung referenziert.

5 Zusammenarbeit mit anderen Stellen

Neben der intensiven Zusammenarbeit mit den Projektpartnern wurden konkrete Problemstellungen, Anforderungen und Lösungsansätze vor und während der Projektlaufzeit mit Industriepartnern diskutiert. Diese Diskussionen waren wichtiger Input für das Projekt und haben eine gemeinsame wissenschaftliche Veröffentlichung initiiert.

Teil II
Eingehende Darstellung

1 Verwendung der Zuwendung und des erzielten Ergebnisses

Die von TLK im Rahmen des Projektes durchgeführten Arbeiten konzentrieren sich im wesentlichen auf die Entwicklung einer Werkzeugkette und der Anwendung dieser zur Erstellung eines Proper Models für die Wärmepumpe eines Thermomanagementsystems in den Arbeitspaketen 5 und 6. In den Arbeitspaketen 1 - 4 wurden vorbereitende Arbeiten durchgeführt, dessen Erkenntnisse und Ergebnisse zur Entwicklung der Werkzeugkette und des Demonstrators genutzt wurden. Die erzielten Ergebnisse werden nachfolgend anhand der Werkzeugkette und des Demonstrators gesammelt dargelegt. Für eine zusammenfassende und vergleichende Methodenübersicht, die von allen Projektpartnern erstellt wurde, sei auf den Gesamtbericht des Vorhabens verwiesen.

1.1 AP5 Werkzeugkette für Thermomanagementsysteme

Im Rahmen des Arbeitspakets 4 hat TLK die Methoden Feedforward Neural Network (FFNN) (siehe z.B. [10]) und Neural Ordinary Differential Equation (NeuralODE) [3] positiv evaluiert. Die Methode der FFNNs wurde dabei als besonders geeignet für die Erstellung recheneffizienter Ersatzmodelle für stationäre Zusammenhänge identifiziert. Die Methode der NeuralODEs eignet sich dagegen für Problemstellungen in denen das zeitabhängige Verhalten einer Komponente oder eines Systems abgebildet werden soll.

Basierend auf diesen Erkenntnissen hat TLK Routinen zur Erstellung von stationären und dynamischen Ersatzmodellen in der Automatisierungssoftware MoBA Automation und dem Python-Modul *tlk_mltoolbox* implementiert. Die MoBA Automation ist eine von TLK entwickelte Software, welche die automatisierte und parallelisierte Ausführung von Workflows, die aus unterschiedlichen Tasks bestehen, ermöglicht. Ein Task stellt dabei eine in Python implementierte Programmeinheit dar, die über definierte Ein- und Ausgänge verfügt und über standardisiertes Logging und Dateibehandlung verfügt. Bei der *tlk_mltoolbox* handelt es sich um ein Python-Modul, das Werkzeuge und Methoden zur Generierung von Trainingsdaten, zum Training und Export von Ersatzmodellen sowie zur Visualisierung von Trainingsergebnissen beinhaltet.

1.1.1 Stationäre Ersatzmodelle

Es wurde ein neuer Task zur Erzeugung von Trainingsdaten zur Erstellung stationärer Ersatzmodelle erstellt. Der neue Task ermöglicht dem Nutzer die Bedatung von vollfaktoriellen und Quasi-Monte-Carlo-Versuchsplänen, sowie Kombinationen dieser, über das in Abbildung 1 dargestellte graphische User-Interface

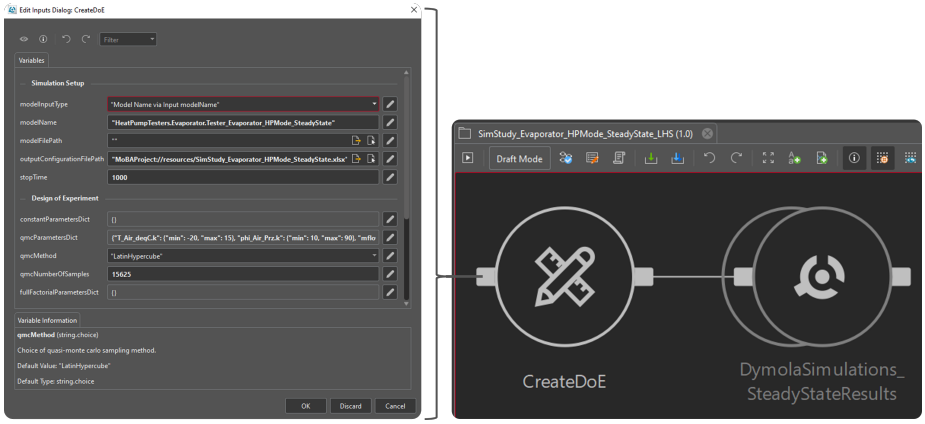

Abbildung 1: Graphisches User-Interface zur Bedatung des Versuchsplanungstasks.

(GUI). Zusätzlich können auch konstante Parameter angegeben werden, die bei allen Simulationen gesetzt werden sollen, um eine vollständige Bedatung der zu simulierenden Modelle zu ermöglichen. Der basierend auf der Nutzereingabe erstellte Versuchsplan wird anschließend als .xlsx-Datei gespeichert. Dies bietet im Vergleich zu anderen, möglicherweise dateneffizienteren Formaten den Vorteil, dass ein Austausch zwischen verschiedenen Nutzern durch die hohe Verbreitung von *Microsoft Excel* leichter ermöglicht wird. Weiterhin ist auch die Bearbeitung und Visualisierung des erstellten Versuchsplans über die in der Industrie weit verbreitete Software möglich. Der Versuchsplan kann anschließend zur Bedatung standardmäßig verfügbarer *MoBA Automation* Workflows zur Durchführung parallelisierter Simulationsstudien genutzt werden. Diese Workflows unterstützen neben der Simulation von Modelica-Modellen mithilfe von Dymola auch die Simulation von Modellen nach dem FMI-Standard [2], sogenannter FMUs, die von den meisten gängigen Simulationstools erstellt werden können. Der aufgebaute Task basiert auf den Open-Source-Python-Bibliotheken *pandas*, *NumPy* und *SciPy*.

Für das Training von FFNNs wurde ein bestehender Task erweitert. Der Task stellt dem Nutzer eine einfach zu bedatende Nutzeroberfläche zur Parametrierung des Trainings und des FFNNs zur Verfügung. Das graphische User-Interface des Tasks ist in Abbildung 2 dargestellt. Im Projektverlauf wurde der für das Training verfügbare *Levenberg-Marquardt*-Optimierungsalgorithmus, der in dem Python-Modul *tlk_ mltoolbox* basierend auf [4] implementiert ist, erweitert. Es wurde die Gauß-Newton-Approximation der Bayes'schen Regularisierung nach [7] implementiert. Diese ermöglicht die Regularisierung der Modellkomplexität im Training, ohne neue vom Nutzer einzustellende Parameter einzuführen. Weiterhin wurde auch der von [13] beschriebene Algorithmus zur Bestimmung des Dämpfungsfaktors des klassischen *Levenberg-Marquardt*-Algorithmus implementiert. Neben dem bereits verfügbaren, erweiterten *tensorflow*-basierten Trai-

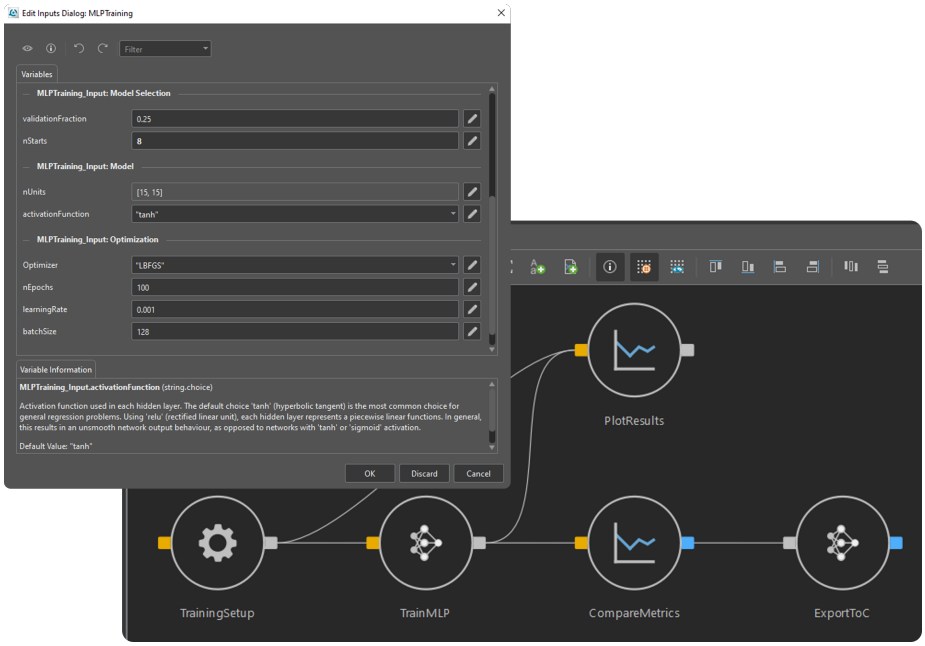

Abbildung 2: Graphisches User-Interface des Tasks zur Erstellung neuronaler Netze in der Software *MoBA Automation*. Der Task ist in dem Workflow zum Training und Export neuronaler Netze instanziiert und wird über das Interface des Workflows bedatet.

ningsalgorithmus wurde zusätzlich ein *scikit-learn*-basierter Algorithmus in der *tlk_ mltoolbox* umgesetzt. Die Verwendung der Python-Bibliothek *scikit-learn* bietet gegenüber *tensorflow* die Vorteile, dass die darin implementierten Methoden aufgrund ihrer geringeren Komplexität einfacher erweiterbar sind und die Bibliothek weniger Abhängigkeiten von anderen Bibliotheken hat. Dies vereinfacht die Verteilung der für die Verwendung der Tasks notwendigen Python-Umgebung.

Für den Export der trainierten Modelle wurde ebenfalls ein bestehender Task verwendet und erweitert. Der Task basiert auf einer in der *tlk_ mltoolbox* implementierten Routine zur automatischen Generierung von C-Code zur Auswertung des neuronalen Netzes. Der generierte C-Code beinhaltet die Modellparameter sowie eine Auswerteroutine und kann somit ohne externe Abhängigkeiten genutzt werden. Im Projektverlauf wurde die Exportroutine erweitert, um den Export der Modelle unabhängig von der für das Training verwendeten Bibliothek zu unterstützen. Zuvor war ausschließlich ein Export von *tensorflow* Modellen möglich. Durch die Erweiterung der Routine wird ein Export von Modellen, die mithilfe des neuen *scikit-learn*-basierten Algrithmus trainiert wurden, ermöglicht. Weiterhin konnte die erweiterte Routine bzw. der Task auch zum Export der im Projektverlauf erstellten dynamischen Ersatzmodelle, die mit den Bibliotheken *PyTorch* und *Jax* trainiert wurden, genutzt werden.

Abbildung 2 zeigt den Workflow zum Training und Export neuronaler Netze basierend auf den beschriebenen, erweiterten Tasks.

1.1.2 Dynamische Ersatzmodelle

Zur Erstellung dynamischer Ersatzmodelle wurden mehrere neue Funktionalitäten in der *tlk_ mltoolbox* umgesetzt.

Für die Erzeugung von Trainingsdaten wurden verschiedene Ansätze zur Generierung dynamischer Anregungen implementiert. Die Ansätze basieren auf dem zufälligen Sampling von Amplituden des Eingangssignals, die entweder zufällig oder mit einem vorgegeben Abstand auf der Zeitachse verteilt werden. Durch Interpolation mit kubisch hermiteschen Splines wird ein kontinuierliches Signal aus den Amplituden erzeugt. Der Nutzer kann optional Halte- bzw. Übergangszeiten zwischen den Amplituden definieren oder zufällig erzeugen lassen. Ein mithilfe dieses Signalgenerators generiertes Signal wurde in Unterabschnitt 1.2 zum Training des dynamischen Ersatzmodells verwendet. In diesem Fall wurde ein fester Abstand zwischen den Amplituden und eine feste Übergangszeit definiert, um ein geglättetes Sprungsignal zu erhalten.

Für das Training von NeuralODEs wurden Ansätze zur Verwaltung und Bereitstellung der zeitabhängigen Trainingsdaten implementiert. Um ein effizientes Training zu ermöglichen, werden die Zeitreihen in Teilstücke nutzerdefinierter Länge unterteilt. Der Nutzer kann dabei auswählen, ob die Teilstücke einmalig zu Beginn des Trainings oder zufällig in jeder Iteration des Trainingsalgorithmus bestimmt werden sollen. Neben der Unterteilung in Teilstücke ist auch die Bereitstellung von zufälligen Teilmengen implementiert. Dies wird im Kontext des maschinellen Lernens als *Batching* und die Teilmengen als *Mini-Batches*

bezeichnet.

Der Export der Modelle erfolgt mithilfe der zuvor genannten Routine zur Generierung von C-Code.

1.1.3 MoBA API

Im Rahmen dieses Forschungsprojekts wurde eine speziell entwickelte Schnittstelle, die MoBA API, implementiert, um den Automatisierungskern der MoBA-Software skriptbasiert anzusteuern. Durch die direkte Parametrierung über Skripte entfällt die Notwendigkeit einer grafischen Benutzeroberfläche, was zu einem erheblichen Zeitgewinn bei der Entwicklung neuer Workflows führt. Die MoBA API erlaubt es, die Erstellung, Validierung und den Export von Ersatzmodellen mithilfe der *tlk_ toolbox* innerhalb eines parallelisierten und automatisierten Workflows abzubilden. Dies bedeutet, dass ressourcenintensive Prozesse optimal auf mehrere Rechenkerne oder sogar verteilte Systeme aufgeteilt werden können. Dadurch werden nicht nur die Rechenzeiten reduziert, sondern auch eine höhere Effizienz und Reproduzierbarkeit der Prozesse gewährleistet. Ein besonderer Vorteil der MoBA API ist ihre Flexibilität in der Anbindung an andere Softwarelösungen. So kann sie problemlos in Matlab, LabVIEW oder anderen Engineering- und Simulationsplattformen integriert werden, um spezifische Workflows zu automatisieren. Dies eröffnet neue Möglichkeiten für den Einsatz der MoBA Automation in verschiedensten Entwicklungsumgebungen und erlaubt eine nahtlose Verbindung zwischen datengetriebenen Modellierungsansätzen und bestehenden Simulations- oder Steuerungsprozessen.

Mit den neuen und erweiterten MoBA Automation Tasks, den neuen Funktionalitäten der *tlk_ mltoolbox* und der MoBA API werden dem Nutzer flexibel einsetzbare Werkzeuge zur Erstellung stationärer und dynamischer Ersatzmodelle bereitgestellt.

1.2 AP6.4 Schnelles Proper Model für die Wärmepumpe eines Thermomanagements

1.2.1 Ausgangssituation

Für die Entwicklung fortschrittlicher Thermomanagementsysteme von E-Fahrzeugen baut TLK zusammen mit seinen Kunden detaillierte Systemmodelle auf. Hierzu wird die von TLK entwickelte TIL Suite, die auf der Modellierungssprache Modelica basiert, verwendet. Ein solches Modell, das im Rahmen von Arbeitspaket 2.4 aufgebaut wurde, ist in Abbildung 3 dargestellt.

Das dargestellte System kann zum Kühlen, Heizen und Entfeuchten des Fahrzeuginnenraums betrieben werden. Durch den Aufbau mit zwei parallelen Verdampfern können darüber hinaus auch die Antriebskomponenten sowie die Batterie gekühlt werden, indem Wärme aus dem Sekundärkreislauf aufgenommen wird. Die aus dem Sekundärkreislauf aufzunehmende Wärme ist dabei vereinfacht als konstante Randbedingung modelliert.

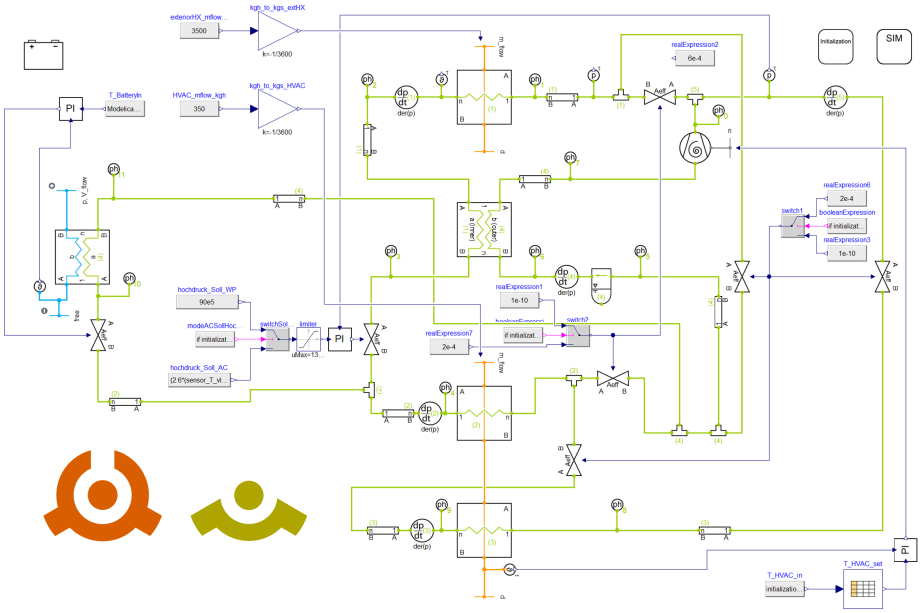

Abbildung 3: Detailliertes Modell einer umschaltbaren CO2-Wärmepumpe für das Thermomangement von E-Fahrzeugen.

Um die Vereisung des Umgebungswärmeübertragers bei niedrigen Umgebungstemperaturen abzubilden, wurden die in der TIL Suite enthaltenen Vereisungsmodelle im Rahmen des Projekts grundsätzlich überarbeitet. Es wurde eine verbesserte Schnittstelle zwischen Wärmeübertrager- und Vereisungsmodellen implementiert, die eine Berechnung der Geometrie der Reif- und Eisschicht in Abhängigkeit der Wärmeübertragergeometrie ermöglicht. Hierdurch konnten verschiedene Modellverbesserungen hinsichtlich Geometrie sowie Stoff- und Transporteigenschaften der Reif- und Eisschicht implementiert werden. Zusätzlich wurde ein neues, diffusionsbasiertes Vereisungsmodell implementiert, dass eine detaillierte Simulation des Reif- und Eisschichtwachstums ermöglicht. Um den Detailgrad des Vereisungsmodells anwendungsabhängig variieren zu können, wurde eine Austauschbarkeit der unterschiedlichen Vereisungsmodelle über die verbesserte Schnittstelle realisiert.

Um die Komfort- und Antriebsanforderungen bei variierenden Randbedingungen zu erfüllen, wird das System mittels drei PI-Reglern geregelt. Die Regelgrößen sind die Zulufttemperatur in den Fahrzeuginnenraum, die Kühlmittel-Vorlauftemperatur der Antriebskomponenten und entweder die Unterkühlung hinter dem Verflüssiger/ Gaskühler oder der Systemhochdruck bei subkritischer respektive transkritischer Wärmeabgabe.

Die Wahl des Soll-Hochdrucks bei transkritischer Prozessführung stellt einen Freiheitsgrad dar, über den die Prozesseffizienz optimiert werden kann. Dies

erfolgt in der Praxis meist über veröffentlichte Korrelationen, spezielle Regelungsstrategien oder Kennfelder. Die zur Erstellung von Kennfeldern nötigen Simulationsstudien sind dabei sehr rechen- und zeitaufwändig, da die Effizienz für jeden untersuchten Betriebspunkt an einer Vielzahl von Hochdrücken berechnet werden muss, um eine Näherung des Optimums zu bestimmen. Eine weitere Möglichkeit zur Bestimmung des Hochdruck-Optimums ist es, den Zusammenhang zwischen Effizienz und Betriebsrandbedigungen durch ein schnell rechnendes Modell abzubilden und dieses zur Optimierung zu nutzen. Dieser Ansatz bietet die Vorteile, dass der gesamte Betriebsbereich abgedeckt werden kann und, unter der Voraussetzung eines geeigneten Modells, eine Echtzeit-Optimierung ermöglicht wird.

Neben der Wahl geeigneter Regler-Sollwerte ist auch das dynamische Antwort- bzw. Regelverhalten entscheidend für einen sicheren und effizienten Betrieb des Thermomanagementsystems. Dieses wird maßgeblich von den Parametern der PI-Regler beeinflusst. Die Auslegung von Reglerparametern erfolgt in der Praxis meist basierend auf linearer Analyse des Systems an ausgewählten Betriebspunkten. Aufgrund der Komplexität des Systems wird dabei häufig nur eine vergleichsweise geringe Anzahl an Betriebspunkten untersucht. Auch modellbasierte Regelungsstrategien oder die Nutzung komplexer Auslegungsverfahren sind meist nur mit hohem Aufwand oder durch starke Modellvereinfachungen realisierbar.

Für die Entwicklung und Auslegung fortschrittlicher Regelungsstrategien werden demnach schnellrechnende, stationäre und dynamische Ersatzmodelle benötigt. Diese Modelle sollten darüber hinaus leicht portierbar sein, um sie in verschiedenen Entwicklungswerkzeugen einsetzen zu können. Zum Zeitpunkt des Projektbeginns nutzte TLK bereits Kennfelder, Polynome und vereinzelt neuronale Netze zur Erstellung von stationären Ersatzmodellen. Insbesondere im Bereich der neuronalen Netze sollte das methodische Verständnis und damit die bestehenden Werkzeugketten verbessert werden, um eine vermehrte Anwendung der Methode zu erreichen. Zur Erstellung von dynamischen Ersatzmodellen standen TLK zum Zeitpunkt des Projektstarts dagegen keine geeigneten Methoden und Werkzeugketten zur Verfügung.

1.2.2 Ergebnisse

Für den Anwendungsfall der Hochdruckbestimmung wurde ein FFNN als stationäres Ersatzmodell für den Zusammenhang

$$\mathrm{COP} = f(\mathbf{x}; \theta) \tag{1}$$

erstellt. Die Größe COP (*Coefficient of Performance*) ist als Verhältnis der Nutzwärme zur aufgenommenen Leistung definiert und beschreibt somit die Prozesseffizienz. Die Prozessrandbedingungen sind in der vektoriellen Eingangsgröße $\mathbf{x}$ zusammengefasst. Die Menge der Modellparameter wird durch die Größe θ beschrieben.

Um den gesuchten Zusammenhang abzubilden, wurde eine umfangreiche Simulationsstudie, bestehend aus 50.000 Simulationen, durchgeführt. Hierzu wur-

Randbedingung	Wertebereich	Einheit
Umgebungstemperatur	-20 - 15	°C
Relative Luftfeuchtigkeit	30 - 90	%
Luftmassenstrom des Außenwärmeübertragers	2880 - 7200	kg/h
Luftmassenstrom des Klimageräts	200 - 700	kg/h
Kühlmittelvolumenstrom des Batteriekühlers	200 - 600	l/h
Sollkühlleistung des Batteriekühlers	500 - 3000	W
Sollhochdruck	60 - 130	bar

Tabelle 1: Randbedingungen der Simulationsstudie zur Erstellung eines stationären Ersatzmodells des detaillierten Thermomanagementsystems.

de eine stationäre Modellvariante des untersuchten Systems aufgebaut, die eine robuste und schnelle Simulation stationärer Systemzustände erlaubt [11]. Die Randbedingungen der Simulationen wurden mit dem Latin-Hypercube-Verfahren [14] aus dem in Tabelle 1 dargestellten Betriebsbereich bestimmt.

Um den Trainingsprozess und die Modellstruktur an den Anwendungsfall anzupassen, wurde eine zweigeteilte Hyperparameterstudie durchgeführt. Der Begriff Hyperparameter fasst dabei alle Parameter zusammen, die vor Beginn des eigentlichen Trainingsprozesses festgelegt werden müssen. Als Vergleichsgröße wird das Bestimmtheitsmaß

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

verwendet. Das Bestimmtheitsmaß gibt Aufschluss darüber, wie viel der in den Daten $\mathbf{y}$ enthaltenen Variabilität durch das Modell beschrieben wird. Ein Bestimmheitsmaß von 1 bedeutet eine vollständige Abbildung der in den Daten enthaltenen Variabilität.

Im ersten Schritt der Hyperparameterstudie wurde ein Modell mit festgelegter Anzahl an Neuronen mit verschiedenen Aktivierungsfunktionen und Optimierern trainiert. Für jede Kombination wurde das Modell 16-mal mit unterschiedlichen initialen Parameterwerten trainiert. Die Ergebnisse dieses Vergleichs sind in Abbildung 4 dargestellt. Die Abbilung zeigt, dass mit einer *Tangens-hyperbolicus*-Aktivierungsfunktion und dem *Levenberg-Marquardt* Optimierungsalgorithmus die besten Ergebnisse erzielt werden. Weiterhin ist aber zu erkennen, dass es vereinzelt zu deutlich schlechteren Trainingsergebnissen kommen kann, weshalb eine Mehrfachinitialisierung der Modellparameter sinnvoll ist.

Im zweiten Schritt der Hyperparameterstudie wurd die Anzahl der verdeckten Schichten und Neuronen pro Schicht variiert. Abbildung 5 zeigt, dass die Modellgüte mit steigender Anzahl verdeckter Schichten steigt. Weiterhin verbessert sich auch die Parametereffizienz des Modells, da eine ähnliche Modellgüte mit einer geringeren Anzahl an Parameter erreicht wird. Basierend auf den Erkenntnissen wird nachfolgend ein FFNN mit drei verdeckten Schichten und mit

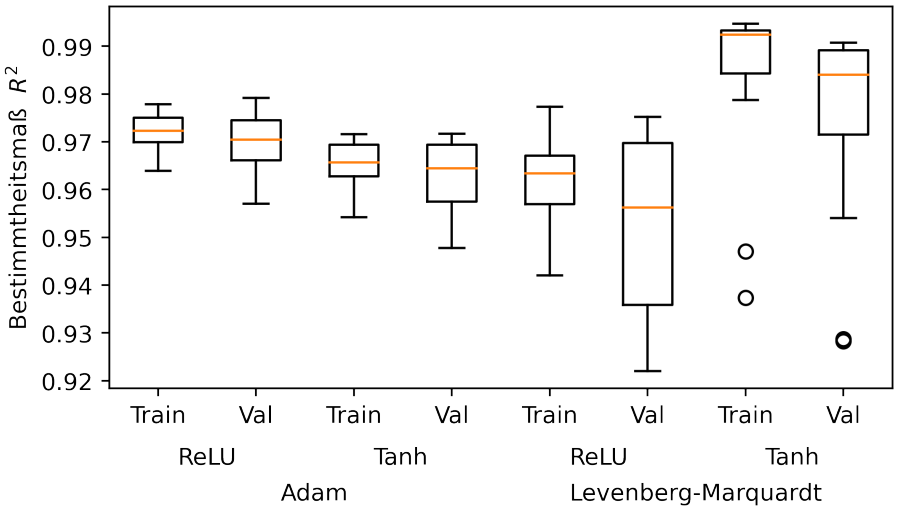

Abbildung 4: Box-Plot der Trainings- und Validierungs-Bestimmtheitsmaße verschiedener Trainings eines 7-50-1 FFNNs zur Approximation des COPs des untersuchten Systems. Train: Ergebnis für Trainingsdaten, Val: Ergebnis für Validierungsdaten, ReLU: *Rectified Linear Unit*, Tanh: *Tangens hyperbolicus*.

jeweils 15 Neuronen verwendet.

Um die Eignung des erstellten stationären Ersatzmodells zur Bestimmung eines COP-optimalen Hochdrucks bewerten zu können, wurden Referenzergebnisse durch eine weitere Simulationsstudie erzeugt. In dieser Simulationsstudie wurden 80 zufällig erzeugte Sätze an Prozessrandbedingungen jeweils mit Hochdrücken von 60 bis 130 bar (Auflösung von 1 bar, 5680 Simulationen) simuliert und der stationäre COP ausgewertet. Für jeden Satz an Randbedingungen konnte somit der COP-optimale Hochdruck mit einer Genauigkeit von 1 bar bestimmt werden.

In Abbildung 6 sind drei beispielhafte Verläufe des stationären Heiz-COPs über dem Hochdruck dargestellt. Die Abbildung zeigt, dass der Verlauf des COPs über dem Hochdruck von dem trainierten Modell ausreichend genau abgebildet werden kann. Auf der rechten Seite von Abbildung 6 ist dabei ein Negativbeispiel mit qualitativen Abweichungen im Verlauf des COPs dargestellt. Das Negativbeispiel veranschaulicht, dass die Ersatzmodell-basierte Optimierung globalisierte Optimierungsalgorithmen erfordern kann, da Modellungenauigkeiten zu lokalen Optima führen können.

Abbildung 7 zeigt die Differenz zwischen dem mithilfe des Ersatzmodells optimierten COPs ($\mathrm{COP}(p_{\mathrm{Opt.}})$) und dem auf Basis der Simulationsstudie ermittelten maximalen COP ($\mathrm{COP}_{\mathrm{max}}$). Zur Optimierung wurde dabei ein einfacher, auf Bisketion basierender Optimierungsalgorithmus verwendet. Die Abbildung zeigt, dass der optimale Heiz-COP bis auf wenige Ausnahmen ausreichend genau

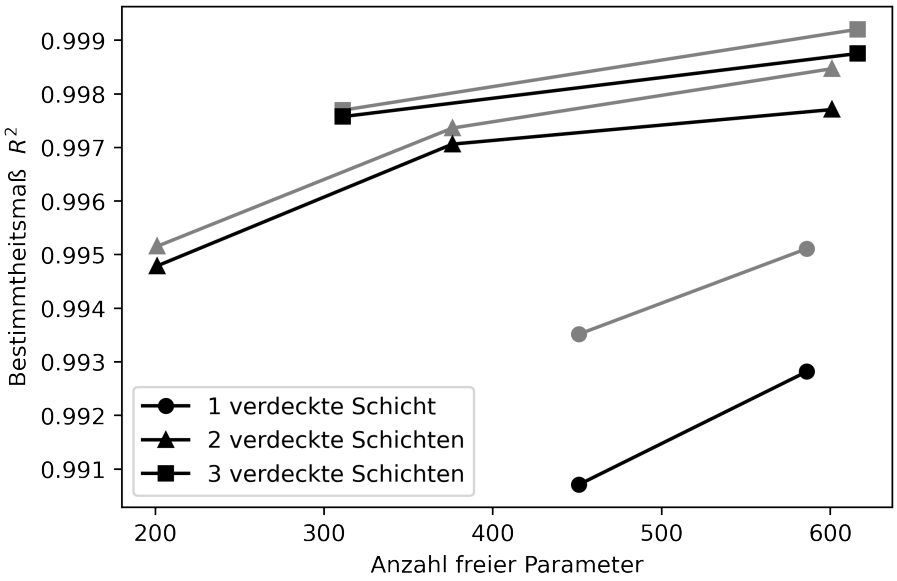

Abbildung 5: Einfluss der Anzahl verdeckter Schichten auf das Bestimmtheitsmaß in Abhängigkeit der Anzahl freier Parameter. Die untersuchten FFNNs bestehen aus jeweils N gleich großen verdeckten Schichten. Grau: Trainingsdaten, Schwarz: Validierungsdaten.

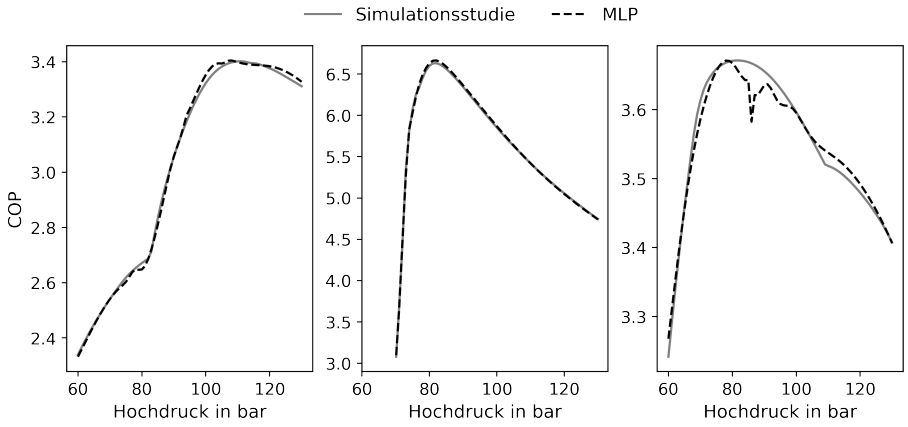

Abbildung 6: Vergleich des approximierten und des simulierten stationären Heiz-COPs für Drücke zwischen 60 und 130 bar anhand drei beispielhafter Simulationsrandbedinungen.

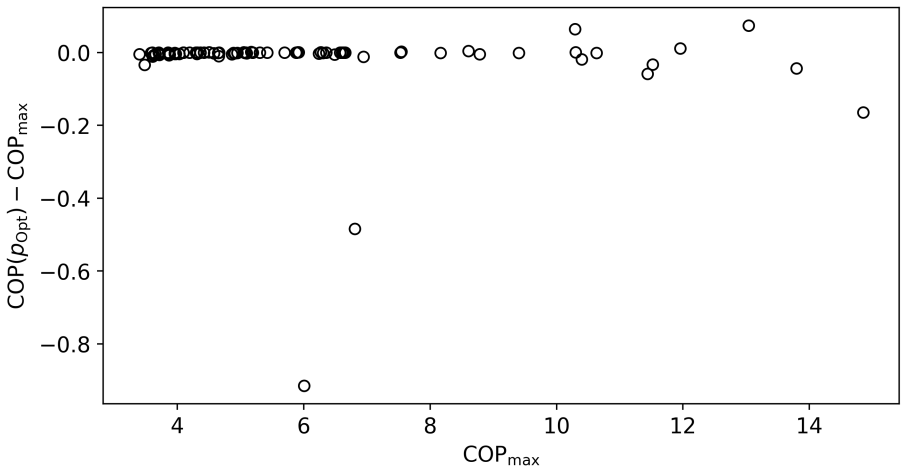

Abbildung 7: Differenz zwischen dem COP bei optimiertem Hochdruck ($\mathrm{COP}(p_{\mathrm{Opt.}})$) und dem maximalen COP auf Basis der Referenzsimulationsstudie ($\mathrm{COP}_{\mathrm{max}}$).

mithilfe der Ersatzmodell-basierten Optimierung bestimmt werden kann. In zwei Fällen ist sogar eine leichte Erhöhung des COPs zu sehen, die wahrscheinlich auf ein sehr schmales Maximum zwischen zwei Druckstufen der Referenzsimulationsstudie zurückzuführen ist. Die Ergebnisse dieses Demonstrator-Use-Cases wurden in [16] veröffentlicht.

Für den Anwendungsfall der Reglerentwicklung wurde ein reduziertes Teilsystem des in Abbildung 3 dargestellten Thermomanagementsystems betrachtet. Das Modell dieses Teilsystems ist in Abbildung 8 dargestellt. Es bildet die Regelstrecke zwischen der Stellgröße Verdichterdrehzahl n und der Regelgröße Zulufttemperatur in den Fahrzeuginnenraum T_{Zuluft} qualitativ ab. Das dynamische Verhalten des physikalischen Modells wurde durch eine NeuralODE, welche die zeitliche Änderung der Regelgröße in Abhängigkeit der Stell- und Störgrößen modelliert, approximiert.

$$\frac{\mathrm{d}T_{\mathrm{Zuluft}}}{\mathrm{d}t} = f(n, \mathbf{u}; \theta) \tag{3}$$

Der Vektor $\mathbf{u}$ fasst die Störgrößen Luftmassenstrom des Klimageräts $\dot{m}_{\mathrm{HVAC}}$ und des Außenwärmeübertragers $\dot{m}_{\mathrm{Umg.}}$ sowie die zusätzliche Stellgröße Ventilstellung x_{EXV} zusammen. Die Menge der Modellparameter wird wie zuvor durch die Größe θ beschrieben.

Um die für das Training der NeuralODE notwendigen Daten zu erzeugen, wurde das Referenzmodell durch ein Signal bestehend aus 200 geglätteten Sprüngen je Eingangsgröße angeregt. Die Reihenfolge, in der sich die Eingangsgrößen ändern, wurde dabei zufällig über die Dauer des Signals variiert, um ein mög-

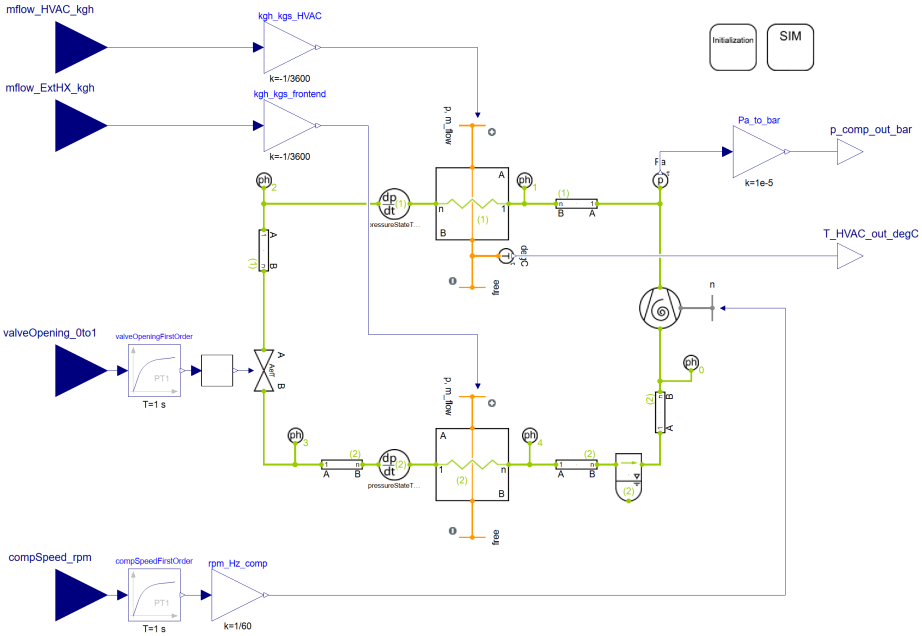

Abbildung 8: Modell eines Teilsystems einer CO2-Wärmepumpe für das Thermomanagement von E-Fahrzeugen.

lichst reichhaltiges Signal zu erhalten. Hierdurch wird gleichzeitig auch die Haltezeit der jeweiligen Amplitude variiert.

Ein Ausschnitt aus dem erzeugten Eingangssignal für die Stell- und Störgrößen sowie die resultierenden Modellantworten sind in Abbildung 9 dargestellt. Die vertikale gestrichelte Linie teilt die dargestellten Trajektorien jeweils in einen Trainings- und einen Validierungsbereich. Die Validierungsdaten werden im Gegensatz zu den Trainingsdaten nicht zur Parameteranpassung, sondern um den Generalisierungsfehler des Modells zu überwachen, genutzt. Die Abbildung zeigt, dass das dynamische Modellverhalten sowohl im Trainings- als auch im Validierungsbereich größtenteils gut wiedergegeben wird. Es ist aber auch ein Bereich größerer Abweichungen von ca. 15.500 bis 16.000 Sekunden zu erkennen.

Um die Modellqualität für die Regelungsentwicklung anwendungsnaher bewerten zu können, wurde das Antwortverhalten des Ersatzmodells auf isolierte Sprünge der Eingangsgrößen getestet. Die Ergebnisse dieses Vergleichs sind in Abbildung 10 dargestellt. Die Abbildung zeigt, dass die maximale Differenz zwischen der approximierten und der Referenz-Zulufttemperatur ca. 3 K entspricht. Da diese verhältnismäßig hohe Abweichung aber im hochdynamischen Bereich unmittelbar nach einem Sprung auftritt, in dem geringe Unterschiede in der Steigung der Trajektorie zu hohen absoluten Fehlern führen, kann sie als vertretbar eingestuft werden. Zu einem Großteil liegen die Fehler des Ersatzmodells unter 1 K, weshalb das Ersatzmodell als hinreichend genau eingestuft wird. Die

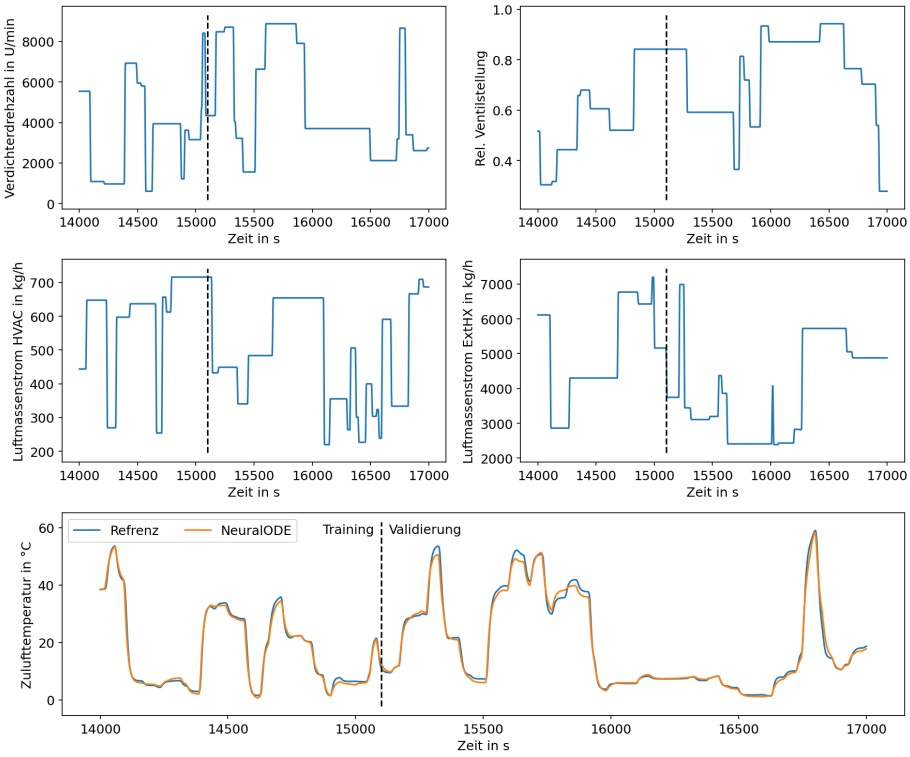

Abbildung 9: Ausschnitt des zum Training der NeuralODE verwendeten Eingangssignals und der resultierenden Modellantworten.

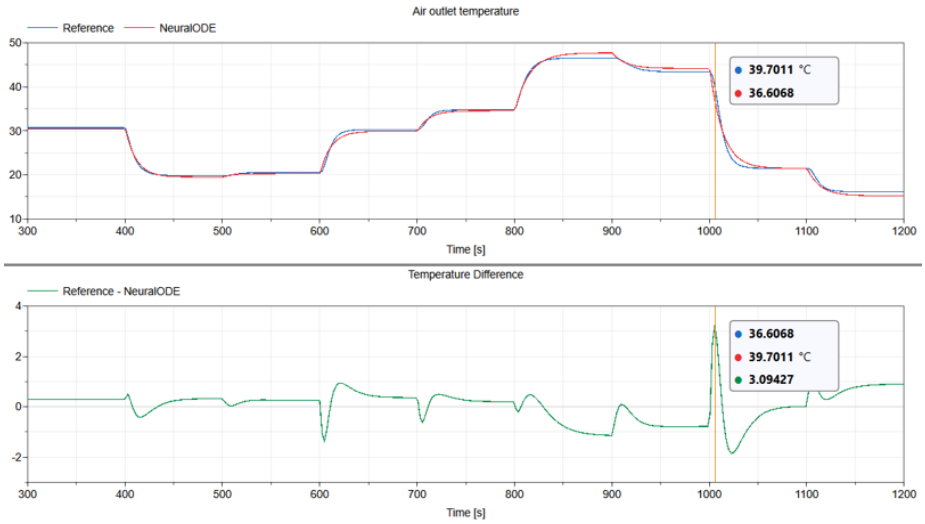

Abbildung 10: Vergleich des Antwortverhaltens des Ersatzmodells mit dem Referenzmodell auf Sprünge der Stell- und Störgrößen.

Simulationgeschwindigkeit des Ersatzmodells ist für die dargestellte Simulation um Faktor 50 höher als die Geschwindigkeit des Referenzmodells.

Um das Ersatzmodell weitergehend zu prüfen, wurde abschließend die Eignung des Modells zur modellbasierten Regelung überprüft. Hierzu wurde ein beispielhaftes Optimalsteuerungsproblem mithilfe der Software CasADi [1] formuliert. Im Gegensatz zu dem Referenzmodell, dass nur unter hohem Zeitaufwand und mit vermutlich geringer Robustheit in CasADi hätte verwendet werden können, konnte das Ersatzmodell mit vergleichsweise geringem Aufwand nativ in CasADi implementiert werden. Die geringe Rechenzeit des Ersatzmodells ermöglichte darüber hinaus auch einen leichtgängigen Entwicklungsprozess, da eine Vielzahl von Optimierungsrechnungen mit unterschiedlichen Problemformulierungen durchgeführt werden konnte. Abbildung 11 zeigt ein beispielhaftes Ergebnis eines solchen Optimierungsproblems. Das Ersatzmodell wurde genutzt, um eine Stellgrößenfolge der Verdichterdrehzahl n zu optimieren, die den Sollwert der Zulufttemperatur T_{Zuluft} bei bekannten Schwankungen der Ventilstellung x_{EXV} möglichst konstant hält. Die optimierte Stellgrößenfolge wurde anhand des Referenzmodells erprobt und dem Systemverhalten mit einem klassischen PI-Regler gegenübergestellt. Abbildung 11 zeigt, dass die optimierte Stellgrößenfolge gegenüber dem PI-Regler zu einer teilweise deutlichen Reduktion der Regelabweichung der Zulufttemperatur führt. Anhand der Phasen längerer Haltezeit der Ventilstellung ist aber auch zu erkennen, dass teilweise nicht vernachlässigbare Regelabweichungen bestehen bleiben. Hieran lässt sich der Einfluss der stationären Modellfehler auf die Güte modellbasierter Regelungen unmittelbar erkennen. Demnach erfordert die Umsetzung modellbasierter Regelungen mit dynamischen Ersatzmodellen eine sehr hohe Modellgüte im gesamten

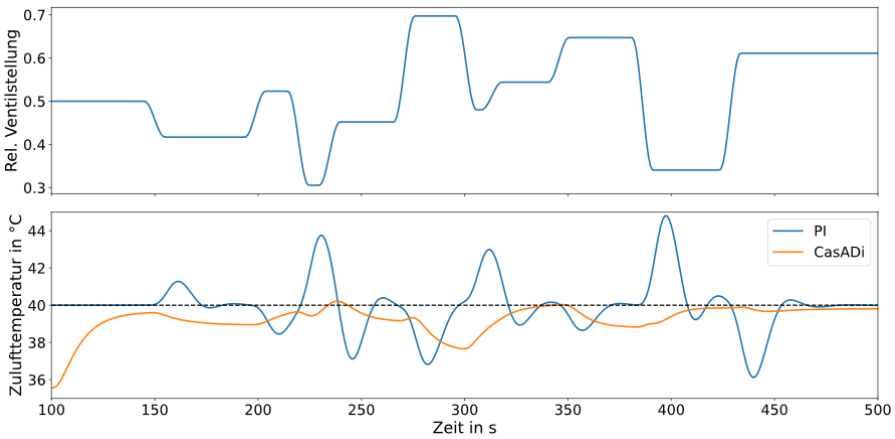

Abbildung 11: Vergleich des Systemantwortverhaltens mit optimierter Stellgrößenfolge und PI-Regeler bei Schwankungen der Ventilstellung.

Betriebsbereich. Alternativ können ausgleichende Maßnahmen, wie parallel geschaltete PI-Regler, eingesetzt werden.

Abschließend werden sowohl der Einsatz stationärer als auch dynamischer Ersatzmodelle basierend auf neuronalen Netzen in der Regelungsentwicklung als sinnvoll erachtet. Insbesondere zur Beschleunigung der Regelungsentwicklung können die schnellrechnenden, leicht portierbaren Ersatzmodelle gewinnbringend eingesetzt werden. Die Produktivitätssteigerung ist dabei unmittelbar an die Dauer zur Modellerstellung gekoppelt. Basierend auf den innerhalb des Projekts erarbeiteten Ergebnisse wurden in AP5 (Unterabschnitt 1.1) leicht verwendbare Werkzeuge zur Erstellung stationärer und dynamischer Modelle umgesetzt.

1.3 AP6.5 ROM eines 3D-Batteriesystems

Im AP6.5 unterstützte TLK das Institut für Thermodynamik der TU Braunschweig bei der Verwendung und Anpassung der Werkzeugkette aus AP5 (Unterabschnitt 1.1) auf die Erstellung von Reduced-Order-Modellen für Batteriesysteme. Die Ergebnisse dieses Arbeitspakets sind von der TU Braunschweig im Gesamtschlussbericht, sowie ihrem partnerspezifischen Bericht dargestellt.

2 Relevante Positionen des zahlenmäßigen Nachweises

Aufseiten der TLK-Thermo GmbH ist der Großteil der entstandenen Kosten dem Personalaufwand zuzurechnen (>99 %). Der restliche Anteil wurde für

Reisen zu Projekttreffen und Konferenzen verwendet.

3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die im Rahmen des Projekts entstandenen KI-Methoden, ihre Anwendung auf Thermomanagementsysteme und die Umsetzung in Softwarewerkzeuge bilden die Grundlage für Dienstleistungen und (inter-)national vermarktbare Softwareprodukte. Weiterhin können die Methoden und Werkzeuge im Anschluss an das Projekt auf andere Anwendungsfelder wie Kältetechnik und Wasserstoffsysteme übertragen werden. Dies begründet die öffentliche Förderung.

4 Voraussichtlicher Nutzen und Verwertbarkeit der Ergebnisse

Die in Unterabschnitt 1.1 beschriebene Werkzeugkette und die in Unterabschnitt 1.2 beschriebenen Ergebnisse sollen wie in Tabelle 2 aufgeführt verwertet werden.

Die erarbeitete Methodik zur Datengenerierung und zum Training von Neural-ODEs soll anhand einer kundennahen Problemstellung veröffentlicht werden. Der aufgebaute MoBA Automation Workflow und das Python-Framework sollen zukünftig vorwiegend in Dienstleistungsprojekten eingesetzt werden.

Die wissenschaftlichen Arbeiten auf dem Gebiet der Generierung von Surrogat-Modellen für dynamische Systeme ist eine bedeutende Vorarbeit für das aktuell laufende, vom BMBF geförderte europäische ITEA4-Projekt OpenSCALING (`https://openscaling.org/`). Im Rahmen des OpenSCALING-Arbeitspakets WP4 werden die gewonnenen Erkenntnisse weiter verfeinert und Vorschläge für eine Standardisierung wichtiger Datenstrukturen und Funktionsschnittstellen erarbeitet, um den in Phymos entwickelten Workflow über standardisierte Modellaustauschformate realisieren zu können. Diese bietet die Möglichkeit, klassische Modellierungstechniken noch enger mit Verfahren des maschinellen Lernens und entsprechender Entwicklungsumgebungen zu verzahnen. TLK führt die Anwendung von gemischt datenbasiert-physikalischen Modellen auf Wärmepumpensysteme im Projekt OpenSCALING fort. Desweiteren werden die Methoden auf Brennstoffzellensysteme für Luftfahrtanwendungen ausgeweitet. Außerdem führt TLK die Forschung an schnellen Batteriemodellen gemeinsam mit der TU Braunschweig im Verbundvorhaben DUPRO (FKZ: 01IS24045A) fort, konkret um die Batteriesicherheit im Fall von thermischem Durchgehen zu erhöhen.

Durch das Projekt wurde ein Promotionsvorhaben bei TLK initiiert.

Art	Bezeichnung	Verwertung	Zeitraum
Tool	MLP Training MoBA Workflow	Service: Surrogaterstellung, bspw. für Softwaresensoren	bis 2025
Methode	DoCE für dynamische Modelle	Veröffentlichung: Anwendung auf reale Problemstellung	bis 2026
Methode	NeuralODE Training	Veröffentlichung: Anwendung auf reale Problemstellung	bis 2026
Tool	NeuralODE Training Python Framework	Service: Surrogaterstellung für modellbasierte Regelungsentwicklung und Simulationsbeschleunigung	bis 2028
Tool	MLP C-Code Generierung	Produkt: Export-Tool (MoBA Automation)	bis 2027
		Service: Surrogateinbindung auf Zielplattform	bis 2025

Tabelle 2: Verwertung der Ergebnisse

5 Fortschritt bei anderen Stellen

Die von Julia Computing entwickelte, cloud-basierte Simulationsplattform JuliaSim enthält Modelle und Tools zur Simulation und Erstellung von Ersatzmodellen für HVAC-Systeme. TLK ist zu diesem Zeitpunkt keine industrielle Anwendung der JuliaSim-Plattform für HVAC-Systeme bekannt.

Der Projektpartner XRG Simulation GmbH hat die SMArtInt-Library zur Integration von tensorflow- und ONNX-Modellen in Modelica veröffentlicht. Im Vergleich zu der von TLK im Rahmen des Projekts implementierten Routine zum Export von Machine-Learning-Modellen als C-Code ist die SMArtInt-Library bei der Modellausführung auf externe Bibliotheken (TfLite Runtime, ONNX Runtime) angewiesen. Hierdurch haben die Machine-Learning-Modelle einen erheblich höheren effektiven Speicherbedarf. Ein Vorteil der Verwendung externer Bibliotheken zur Modellausführung ist der höhere Umfang unterstützter Modellarchitekturen.

Der Fortschritt in den Bereichen Ersatzmodelle für HVAC-Systeme und Integration von Ersatzmodellen in Modelica bestätigt das hohe Potenzial der im Projekt untersuchten Methoden und Anwendungen.

6 Erfolgte und geplante Veröffentlichungen der Ergebnisse

Es sind Veröffentlichungen im Rahmen von Konferenzen, Journals und studentischen Arbeiten erfolgt. Die bei TLK initiierte Promotion wird voraussichtlich 2026 abgeschlossen.

- Jugert, R.; Schatz, H.: Schnellrechnende diskretisierte Kältekreislaufmodelle für umfangreiche PKW-Nutzungstudien. HDT-Tagung Fahrzeugklimatisierung, 25./26. Juni 2024.
- Schatz, H.; Varchmin, A.: Einsatz neuronaler Netze in der Betriebsstrategie und Regelung von CO2-Kältekreisläufen, 10. VDI-Fachkonferenz Thermomanagement für elektromotorisch angetriebene PKW, Nürnberg, 9.-10. März 2022.
- Westhaeuser, J.; Schatz, H.; Albrecht J.-C.; Tegethoff, W.; Lemke, N.; Koehler, J.: Analysis of cyclic frosting and defrosting of a vehicle heat pump, International Journal of Refrigeration, Mai 2023.
- Kuhlmann, F.: Betriebspunktübergreifende Reglerauslegung mithilfe gradientenbasierter Optimierung, Masterarbeit, TU Braunschweig, 2021.
- Schatz, H.: Untersuchung modellbasierter Betriebsstrategien von CO2-Kältekreisläufen auf Basis neuronaler Netze, Masterarbeit, TU Braunschweig, 2022.

- Mücke, K.: Prozess zum dynamischen Parameterfitting eines Kältemittelverdichtermodells, Masterarbeit, TU Braunschweig, 2023.

Teil III
Literaturverzeichnis

Literatur

[1] Joel A. E. Andersson u. a. „CasADi – A software framework for nonlinear optimization and optimal control“. In: *Mathematical Programming Computation* 11.1 (2019), S. 1–36. DOI: 10.1007/s12532-018-0139-4.

[2] Modelica Association. *Functional Mock-up Interface*. URL: https://fmi-standard.org/.

[3] Ricky TQ Chen u. a. „Neural ordinary differential equations“. In: *Advances in neural information processing systems* 31 (2018).

[4] Fabio Di Marco. *Tensorflow Levenberg-Marquardt*. 2022. URL: https://github.com/fabiodimarco/tf-levenberg-marquardt.

[5] Philipp Ebeling. *Verbundprojekt AUTO-GEN - Teilautomatisierte Generierung physik- und daten-basierter thermodynamischer Modelle für das Design und den Betrieb komplexer Systeme in der E-Mobilität: Schlussbericht KMU-innovativ*. 2024.

[6] Björn Flieger. *Verbundprojekt DIMOBA - Diagnose und Management von Hotspots in Batteriesystemen: Schlussbericht KMU-innovativ*. Hrsg. von Technische Informationsbibliothek. 2019. DOI: 10.2314/KXP:1703876067.

[7] F. Dan Foresee und Martin T. Hagan. „Gauss-Newton approximation to Bayesian learning“. In: *Proceedings of international conference on neural networks (ICNN'97)*. Bd. 3. IEEE. 1997, S. 1930–1935.

[8] TLK-Thermo GmbH. *MoBA Automation*. URL: https://www.tlk-thermo.com/de/software/moba-automation.

[9] TLK-Thermo GmbH. *TIL Suite*. URL: https://www.tlk-thermo.com/de/software/til-suite.

[10] Ian Goodfellow, Yoshua Bengio und Aaron Courville. *Deep Learning*. http://www.deeplearningbook.org. MIT Press, 2016.

[11] René Jugert und Henrik Schatz. „Schnellrechnende diskretisierte Kältekreislaufmodelle für umfangreiche PKW-Nutzungstudien“. In: *HDT-Tagung Fahrzeugklimatisierung*. Juni 2024.

[12] Christian Kaiser. „Untersuchungen zur Effizienz- und Leistungssteigerung von Omnibusklimaanlagen“. Dissertation. Aachen: Technische Universität Braunschweig, 2020.

[13] F. Madsen, Nielsen H. B. und Tingleff O. „Methods for non-linear least squares problems“. Technical University of Denmark, Informatics and Mathematical Modelling. 2004.

[14] Michael D. McKay, Richard J. Beckman und William J. Conover. „A comparison of three methods for selecting values of input variables in the analysis of output from a computer code“. In: *Technometrics* 42.1 (2000), S. 55–61.

[15] Michael Nöding, Wilhelm Tegethoff und Jürgen Köhler. „Zero Gradient Control for R-744 Refrigeration Cycles“. In: *International Journal of Refrigeration* (2019).

[16] Henrik Schatz und Andreas Varchmin. „Einsatz neuronaler Netze in der Betriebsstrategie und Regelung von CO2-Kältekreisläufen“. In: *VDI-Fachkonferenz Thermomanagement für elektromotorisch angetriebene PKW* 10 (März 2022).

[17] Christian Schulze. „A Contribution to Numerically Efficient Modelling of Thermodynamic Systems“. Dissertation. Braunschweig: Technische Universität Braunschweig, 2013.

[18] Wilhelm Tegethoff und Christian Peteranderl. „Heating and air conditioning of battery electric city buses by reversible R744 heat pump modules“. In: *Oltersdorf, T. et al.: Case studies and design guidelines for optimization of components and systems, HPT Annex 54, Heat pump systems with low GWP refrigerants* (2022).

[19] Andreas Varchmin u. a. *Schnelle Entwicklung intelligenter modellgestützter Regler für das flexible Thermomanagement von E-Fahrzeugen (Reflex Thermo): leicht gekürzter Schlussbericht zu einem vom BMBF geförderten Verbundvorhaben zum Themenfeld "Energieeffiziente und sichere Elektromobilität" (STROM 2)*. Hrsg. von Technische Informationsbibliothek. 2016. DOI: 10.2314/GBV:871330253.

[20] Andreas Varchmin u. a. *Verbundprojekt VEOTOP - Verfahren zur optimalen Synthese und Topologieoptimierung komplexer thermischer Energiesysteme: Schlussbericht KMU-innovativ*. Hrsg. von Technische Informationsbibliothek. 2022. DOI: 10.2314/KXP:1842072846.

[21] Jochen Westhäuser u. a. „Analysis of cyclic frosting and defrosting of a vehicle heat pump“. In: *International Journal of Refrigeration* (2023).

Berichtsblatt

1. ISBN oder ISSN geplant	**2. Berichtsart (Schlussbericht oder Veröffentlichung)** Schlussbericht
3. Titel Verbundvorhaben PHyMoS: Proper Hybrid Models for Smarter Vehicles Schlussbericht zum Teilvorhaben der TLK-Thermo GmbH	
4. Autor(en) [Name(n), Vorname(n)] Schatz, Henrik Varchmin, Andreas Ebeling, Philipp	**5. Abschlussdatum des Vorhabens** 31.08.2024
	6. Veröffentlichungsdatum 26.02.2025
	7. Form der Publikation Document Control Sheet
8. Durchführende Institution(en) (Name, Adresse) TLK-Thermo GmbH, Rebenring 31, 38106 Braunschweig	**9. Ber.-Nr. Durchführende Institution**
	10. Förderkennzeichen 19I20022C
	11. Seitenzahl 25
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	**13. Literaturangaben** 21
	14. Tabellen 2
	15. Abbildungen 11
16. DOI (Digital Object Identifier)	
17. Vorgelegt bei (Titel, Ort, Datum)	

18. Kurzfassung

Ziel des Vorhabens war es, sogenannte Proper Models für unterschiedliche Fragestellungen als Simulationsmodelle zur Verfügung zu stellen und Methoden zur Erzeugung dieser zu entwickeln. Proper Models nutzen vorhandenes physikalisches Wissen in dateneffizienter Weise, sollen skalierbar sein und sollen die Vorteile physikbasierter und datenbasierter Modellierungstechniken vereinen.

Im Teilvorhaben der TLK-Thermo GmbH wurden Proper Models für Thermomanagementsysteme, insbes. Wärmepumpen, entworfen und evaluiert, sowie Methodiken zur Erzeugung dieser erforscht.

Mit Feedforward Neural Networks wurde eine statisch-datenbasierte Methode verwendet, um den Coefficient of Performance einer umschaltbaren Wärmepumpe unter diversen Betriebsbedingungen vorherzusagen. Als dynamisch-datenbasierte Methode wurden echtzeitfähige Neural-ODEs zur Verwendung in der Regelungsentwicklung und -optimierung verwendet.

Es wurden signifikante Beschleunigungen in den Rechenzeiten erzielt. Die Methoden zur automatisierten und parallelisierten Erzeugung der Proper Models wurden als Tool-Prototypen innerhalb der TLK-Software MoBA Automation realisiert. Für den Export der schnellen Modelle und Import in andere Simulationsumgebungen wurde ein universell verwendbares Python-Tool entwickelt.

19. Schlagwörter

Machine Learning, Deep Learning, Neuronale Netze, Physikbasierte Modellierung, Wärmepumpe, Modelica, FMI

20. Verlag	**21. Preis**

Nicht änderbare Endfassung mit der Kennung 2633816-7

Document control sheet

1. ISBN or ISSN geplant	**2. type of document (e.g. report, publication)** Veröffentlichung (Publikation)
3. title Verbundvorhaben PHyMoS: Proper Hybrid Models for Smarter Vehicles Schlussbericht zum Teilvorhaben der TLK-Thermo GmbH	
4. author(s) (family name, first name(s)) Schatz, Henrik Varchmin, Andreas Ebeling, Philipp	**5. end of project** 31.08.2024
	6. publication date 26.02.2025
	7. form of publication Document Control Sheet
8. performing organization(s) name, address TLK-Thermo GmbH Rebenring 31 38106 Braunschweig	**9. orginators report no.**
	10. reference no. 19I20022C
	11. no. of pages 25
12. sponsering agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	**13. no. of references** 21
	14. no. of tables 2
	15. no. of figures 11
16. DOI (Digital Object Identifier)	
17. presented at (title, place, date)	
18. abstract The aim of the project was to make so-called proper models available as simulation models for different problems and to develop methods for generating them. Proper models use existing physical knowledge in a data-efficient manner, should be scalable and should combine the advantages of physics-based and data-based modeling techniques. In the TLK-Thermo GmbH sub-project, proper models for thermal management systems, in particular heat pumps, were designed and evaluated, and methods for generating them were researched. Feedforward neural networks were used as a static data-based method to predict the coefficient of performance of a switchable heat pump under various operating conditions. Real-time neural ODEs were used as a dynamic data-based method for use in control development and optimization. Significant acceleration in simulation times was achieved. The methods for automated and parallelized generation of the Proper Models were implemented as tool prototypes within the TLK software MoBA Automation. A universally usable Python tool was developed for exporting the fast models and importing them into other simulation environments.	
19. keywords Machine Learning, Deep Learning, Neural Networks, Physics-based modeling, Heat pump, Modelica, FMI	
20. publisher	**21. price**

Nicht änderbare Endfassung mit der Kennung 2637692-5