

**Future Energy
Lab**

BERICHT

Effizienzsteigerungen im Fernwärmesystembetrieb durch maschinelles Lernen (ML4FW)

Use-Case-Entwicklung und -Bewertung

Ein Projekt der

dena

Impressum

Herausgeber:

Deutsche Energie-Agentur GmbH (dena)

Chausseestraße 128 a

10115 Berlin

Tel.: +49 30 66 777- 0

Fax: +49 30 66 777- 699

E-Mail: info@dena.de

Internet: www.dena.de, www.future-energy-lab.de

Autorinnen und Autoren:

Dietrich Schmidt, Fraunhofer IEE

Stefan Faulstich, Fraunhofer IEE

Christian Gück, Fraunhofer IEE

Clara Holzhüter, Fraunhofer IEE

Dennis Lottis, Fraunhofer IEE

Lukas Koppenhagen, Fraunhofer IEE

Lisa Marie Martmann, Fraunhofer IEE

Dinah Elena Hollermann, Fraunhofer IEE

Herbert Sinnesbichler, Fraunhofer IBP

Cosima Wörle, Fraunhofer IBP

Nicola Kleppmann, SAMSON/KT-Elektronik

Jonas Theiss, SAMSON

Marko Drews, Neuwoba

Sebastian Grimm, AGFW e.V.

Lennart Wernicke, dena – Deutsche Energie-Agentur

Benedikt Pulvermüller, dena – Deutsche Energie-Agentur

Konzeption und Gestaltung:

The Ad Store GmbH

Stand:

01/2026

Alle Rechte sind vorbehalten. Die Nutzung steht unter dem Zustimmungsvorbehalt der dena.

Bitte zitieren als:

Deutsche Energie-Agentur (Hrsg.) (dena, 2026) „Future Energy Lab, Bericht: Effizienzsteigerungen im Fernwärmesystembetrieb durch maschinelles Lernen (ML4FW) – Use-Case-Entwicklung und -Bewertung“



Bundesministerium
für Wirtschaft
und Energie

Die Veröffentlichung dieser Publikation erfolgt im Auftrag
des Bundesministeriums für Wirtschaft und Energie.
Die Deutsche Energie-Agentur GmbH (dena) unterstützt die
Bundesregierung in verschiedenen Projekten zur Umsetzung
der energie- und klimapolitischen Ziele im Rahmen der
Energiewende.

Inhalt

Vorwort	4
Executive Summary	6
1. Hintergrund	10
1.1 Relevanz der Fernwärme für die Energiewende	11
1.2 Digitalisierung in der Fernwärme	11
1.3 Potenziale für Machine Learning in der Fernwärme	12
1.4 Use Case: Optimierung der Rücklauftemperaturen	12
1.5 Zentrale Bedeutung der Wohnungswirtschaft für die Fernwärme	13
1.6 Einordnung des gewählten Use Case	13
1.7 Aufbau und Struktur des Entwicklungsprojekts	14
2. Projektteil 1: Umsetzung des Use Case „Optimierung von HAST-Reglerparametern“	15
2.1 Schaffung der Datengrundlage für das Projekt	16
2.2 Aufbau eines Simulationsmodells für die untersuchten Anlagen	18
2.3 Erstellung der ML-Modelle und ihr Training	20
2.4 Beschreibung der Umsetzungsgebäude für den Feldtest	22
2.5 Ergebnisse aus dem Feldtest	24
2.6 Potenziale zur Optimierung durch den Projektansatz	33
2.7 Fazit der Umsetzung des Use Case	34
3. Projektteil 2: Methodik zur Bewertung von ML Use Cases	35
3.1 Beschreibung der Methodik	36
3.2 Ergebnisse der wissenschaftlichen Bewertung	39
3.3 Exemplarische Auswertung des Use Case	41
3.4 Diskussion und Einordnung der Ergebnisse	43
3.5 Fazit und Handlungsempfehlungen zur Bewertungsmethode	44
4. Schlussfolgerungen und Ausblick	45
4.1 Schlussfolgerungen	46
4.2 Lessons Learned	46
4.3 Ausblick	47
Abbildungsverzeichnis	49
Tabellenverzeichnis	50
Literaturverzeichnis	51
Abkürzungsverzeichnis	53
Anhang	54

Vorwort

Vor dem Hintergrund des voranschreitenden Klimawandels ist die Dekarbonisierung des Wärmesektors eine der drängendsten Herausforderungen unserer Zeit. Über die Hälfte des gesamten Endenergieverbrauchs in Deutschland entfällt auf Wärme, ein Sektor, der nach wie vor maßgeblich durch fossile Energieträger geprägt ist und somit erheblich zu unseren nationalen Treibhausgasemissionen beiträgt. Um die ehrgeizigen Klimaschutzziele der Bundesregierung zu erreichen und unsere Abhängigkeit von fossilen Brennstoffen zu überwinden, braucht es entschlossene Maßnahmen, innovative Technologien und eine konsequente digitale Transformation des Wärmesystems.

Das Future Energy Lab (FEL) der Deutschen Energie-Agentur (dena) engagiert sich seit Jahren mit wegweisenden Projekten für diesen digitalen Wandel im Energiesystem und erprobt dabei auch den Einsatz von Künstlicher Intelligenz (KI). Im FEL wurden bereits mehrere wegweisende Vorhaben dazu umgesetzt: So hat das Projekt „EnerKI“ die Potenziale von KI für die Energiewirtschaft identifiziert und wertvolle Impulse für eine breitere Anwendung gegeben. Das Folgeprojekt „Data4Grid“ hat praxisnah gezeigt, wie KI-Lösungen zur Optimierung der Stromnetzsteuerung eingesetzt werden können. Mit dem Projekt „KI in Fernwärme“ haben wir konkrete Blaupausen für den Einsatz von KI speziell in der Wärmeversorgung entwickelt. Auf dieser erfolgreichen Vorarbeit baut das Projekt „ML4FW – Maschinelles Lernen für Fernwärme“ nun gezielt auf und ergänzt sie um eine entscheidende technische Dimension: die direkte Anwendung von Machine Learning zur Optimierung von Bestandsanlagen.

Aktuell rückt das Fernwärmesystem verstärkt ins Blickfeld politischer und wirtschaftlicher Akteure. Als kollektive Infrastruktur und Plattform für die Integration erneuerbarer Wärmequellen besitzt Fernwärme das Potenzial, urbane Quartiere effizienter, resilenter und nachhaltiger zu machen. Doch um dieses Potenzial tatsächlich zu heben, bedarf es weit mehr als nur neuer Erzeugungsanlagen und einer modernisierten Infrastruktur: Entscheidend ist eine digitale Infrastruktur, die eine intelligente, datengetriebene Betriebsoptimierung ermöglicht und sowohl ökologisch als auch ökonomisch nachhaltige Ergebnisse liefert.

Vor diesem Hintergrund nimmt das Projekt ML4FW eine entscheidende Rolle ein: Es greift die drängende Notwendigkeit auf, die vorhandenen Potenziale der Digitalisierung gezielt und praktisch nutzbar zu machen, und demonstriert eindrucksvoll, wie die Wärmewende mit intelligenten Technologien konkret beschleunigt werden kann. ML4FW demonstriert in der Praxis, wie digitale Technologien, insbesondere Machine Learning (ML), zu einer signifikanten Effizienzsteigerung in Bestandsquartieren beitragen können.

Neben der Umsetzung des Use Case wurde im Rahmen des Projekts erstmals ein methodisch fundiertes Bewertungsverfahren für den Einsatz von Künstlicher Intelligenz in der Fernwärme entwickelt. Diese Methodik ermöglicht es Stakeholdern der Energie- und Wohnungswirtschaft, Digitalisierungsvorhaben frühzeitig hinsichtlich ihres Nutzens, ihres Aufwands und ihrer Risiken einzuschätzen. Beide Ergebnisse sind signifikante Beiträge zur digitalen Transformation der Wärmeversorgung und stehen als Open-Source-Anwendung frei zur Verfügung, wodurch insbesondere kleinere Stadtwerke und deren Dienstleister in die Lage versetzt werden, die Chancen der Digitalisierung greifbar zu nutzen.

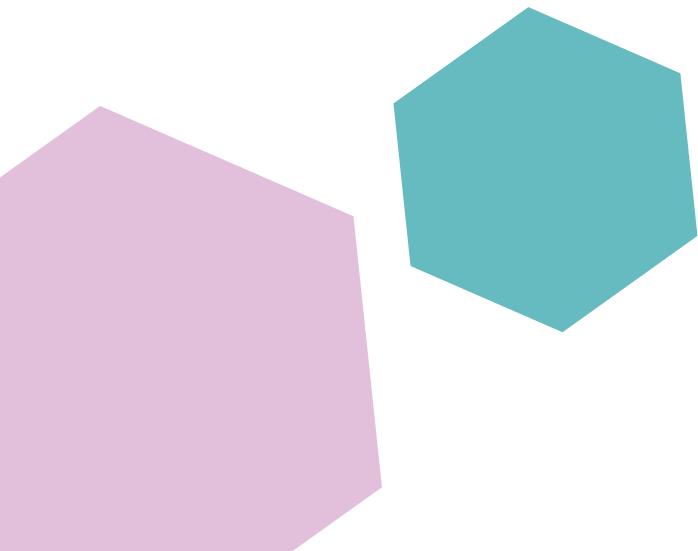
Mit diesem Bericht möchten wir Entscheiderinnen und Entscheider aus Politik, Wohnungswirtschaft, Energieversorgung, Wissenschaft und Digitalbranche über die Erkenntnisse und Ergebnisse von ML4FW informieren und gleichzeitig dazu ermutigen, die Chancen digitaler Technologien aktiv zu nutzen. Unser herzlicher Dank gilt allen Projektpartnern, insbesondere dem Fraunhofer IEE und IBP, der Neuwoba und SAMSON, für ihre engagierte und innovative Zusammenarbeit. Ein besonderer Dank gilt zudem dem Bundesministerium für Wirtschaft und Energie für die Förderung dieses wichtigen Projekts.

Wir laden Sie herzlich ein, gemeinsam mit uns die nächsten Schritte zu gehen und die digitale Wärmewende zur gelebten Realität werden zu lassen.



Lennart Wernicke

Benedikt Pulvermüller



Executive Summary

Die Fernwärme stellt eine leistungsfähige Infrastruktur dar, die verschiedene erneuerbare Energiequellen effizient bündeln und großflächig bereitstellen kann. Damit ermöglicht sie eine klimafreundlichere Wärmeversorgung für Stadtquartiere, Industriearale und öffentliche Einrichtungen. Die Transformation der Fernwärmesysteme ist notwendig, um den Ausstieg aus fossilen Brennstoffen wie Kohle und Erdgas zu vollziehen. Erneuerbare Alternativen wie Großwärmepumpen, Solarthermie, Geothermie oder industrielle Abwärme sind gefragt, um fossile Wärmeerzeugung abzulösen. Ein wesentlicher Schritt zur Dekarbonisierung des Wärmesektors ist die Digitalisierung der Fernwärmesysteme. Intelligente Steuerungssysteme können den Energieverbrauch optimieren, die Integration erneuerbarer Energien erleichtern und vorausschauende Wartung ermöglichen, wodurch Ausfälle und ineffiziente Betriebszustände reduziert werden. Insgesamt stärkt die Digitalisierung die Effizienz und Flexibilität des Fernwärmesektors und sorgt für eine noch zuverlässigere Wärmeversorgung.

Ziel des von der dena geförderten Projekts „ML4FW – Maschinelles Lernen für Fernwärme“ ist es, die Anwendbarkeit und Effektivität von Methoden des Machine Learning (ML) für den realen Fernwärmebetrieb zu evaluieren und zu demonstrieren.

Dafür wurden im Rahmen der Umsetzung eines Use Case Reglerparameter von Hausstationen (HAST) durch ML-Methoden optimiert. So konnten eine Absenkung der sekundärseitigen Rücklauftemperaturen und damit eine Effizienzsteigerung der FernwärmeverSORGUNG erreicht werden. Der Use Case zeigt die Anwendbarkeit und Effektivität von ML-Methoden für Fernwärmenetze am Beispiel des Auto- und Continuous-Commissioning von Regelgeräten an realen Fernwärme-Hausstationen.

Dazu wurde in der Use-Case-Demonstration die Gesamtsystemarchitektur zum Auto-/Continuous-Commissioning von HAST aufgebaut, die eine flexible Anpassung der Reglerparameter und damit eine datengetriebene Optimierung ermöglicht. Das Auto-Commissioning umfasst die automatisierte Anpassung von Reglerparametern an individuelle Betriebsbedingungen, während Continuous-Commissioning zusätzlich eine kontinuierliche Anpassung an sich verändernde Betriebsbedingungen ermöglicht. Die Datenerfassung erfolgt automatisiert über digitale Verbrauchszähler und Regler, die an die Plattform SAM DISTRICT ENERGY angebunden sind. Der Fokus lag auf den Liegenschaften der Neuwoba in Neubrandenburg, wo Liegenschaften mit quasi identischen Anlagenschemata betrachtet und somit auch verglichen werden konnten. Zur Umsetzung und Bewertung des Use Case wurden aktuelle Verbrauchsdaten und historische Daten aus der Plattform verwendet. Dabei mussten Herausforderungen wie die Hardware-Anbindungen und das Füllen von Datenlücken bewältigt werden, um hinreichend nutzbare Datensätze für die Simulationen und das ML-Training zu generieren.

Zur Modellierung der Rücklauftemperaturen der Liegenschaften in Abhängigkeit von Heizkurvenparametern wurden Simulationsmodelle erstellt. Die Validierung der Simulationsmodelle erfolgte anhand gemessener Rücklauftemperaturen, wobei eine mittlere Abweichung von etwa 1 K erzielt wurde.

Der entwickelte Ansatz für das Training der ML-Modelle zeigt, dass auch mit einer begrenzten Datenbasis aussagekräftige Optimierungen erreicht werden können. Die ML-Modelle arbeiten mit einem 1D-Convolutional Neural Network (1D-CNN), das sich als effektiv für die Analyse von Zeitreihen erwiesen hat. Die Trainingsdatensätze bestehen aus Simulationen, die durch verschiedene Reglerparametereinstellungen generiert wurden.

Die Feldtests in den Liegenschaften demonstrieren, dass durch die optimierten Reglerparameter eine signifikante Reduktion der Rücklauftemperaturen von 2 bis 3 K und eine Senkung der kumulierten Wärmemenge über die Vergleichstage von ungefähr 8-9 % erzielt werden kann. Die Antworten bei der durchgeführten Nutzerbefragung zeigen eine hohe Zufriedenheit mit der Heizungsregelung, was darauf hinweist, dass die vorgenommenen Anpassungen effektiv waren. In dem Projekt wurde gezeigt, dass das betrachtete Verfahren zur Integration von ML-Methoden zur Optimierung von Reglerparametern von Hausstationen in der Fernwärme funktioniert, und damit der „Proof of Concept“ erbracht.

Durch die implementierten Regelung im realen Betrieb wurde eine Senkung der Rücklauftemperatur um mindestens 2 K erreicht. Dies bedeutet eine Senkung der kumulierten Wärmemenge über die Vergleichstage von ungefähr 8-9 % und damit eine Einsparung bei den Heizkosten gegenüber dem nicht optimierten System. Für eine Aussage zu möglichen generellen Energieeinsparungen durch die Anpassungen muss die Datenbasis für die Auswertung erweitert werden.

Das Projekt verdeutlicht, dass die Potenziale des Ansatzes besonders in der verbesserten Regelbarkeit in Übergangszeiten (Frühjahr/Herbst) liegen. Eine dynamisch angepasste Heizkurve könnte hier zusätzliche Effizienzgewinne erzielen. Darüber hinaus wurde die Möglichkeit aufgezeigt, den Ansatz auf andere Gebäude mit ähnlicher Datenlage zu übertragen. Der Ansatz des Projekts zeigt, dass keine umfassende Sensorik (z. B. Innenraumtemperaturmessung) für die Anwendung der ML-Verfahren notwendig ist.

Die Durchführung des Use Case hat gezeigt, dass der Erfolg von KI- und ML-Anwendungen im Fernwärmesektor weniger von komplexen Algorithmen als von sauberen Prozessen, realistischen Zeitplänen sowie einer belastbaren Daten- und IT-Basis abhängt. Aus den technischen und organisatorischen

Erfahrungen lassen sich praxisnahe Empfehlungen ableiten, die zukünftige Projekte beschleunigen und typische Fallstricke vermeiden helfen. Im Use Case hat sich ergeben, dass die Erfassung der Daten und die Bereitstellung der Hardware mit den notwendigen Genehmigungen mehr Zeit beanspruchen als die Entwicklung des Codes und der Modelle. Dies ist insbesondere in der Projektvorbereitung zu beachten. Bei der Datenerfassung hat sich die Priorisierung von Datenqualität vor zusätzlichen Messgrößen bewährt. Auch die Gewährleistung aller relevanten Zugänge, beispielsweise zu Schnittstellen, war essenziell für den Erfolg. Sind diese Grundlagen gegeben, lassen sich in typischen Gebäuden nach wenigen Wochen Effizienzgewinne erzielen.

Trotzdem sind eine Skalierung des Ansatzes in der Praxis und eine Standardisierung des Modells aufgrund individueller Gegebenheiten (wie Gebäudetechnik, Nutzerverhalten, hydraulische Einbindung) anspruchsvoll. Eine direkte Übertragung der Methodik ist nicht ohne Weiteres möglich. Daher besteht weiterer Forschungsbedarf, um übertragbare Modellierungsansätze für typische Gebäudekonfigurationen zu entwickeln, ML-Ops Pipelines zur automatisierten Kalibrierung und Validierung zu nutzen und rein datenbasierte Modelle zur dynamischen Betriebsoptimierung weiter zu erproben.

Neben der Use-Case-Demonstration wurde eine Möglichkeit geschaffen, unterschiedliche Ansätze zur Nutzung von ML-Verfahren in vergleichbarer Art und Weise zu evaluieren. Die erarbeitete Bewertungsmethode basiert auf einem zweistufigen Konzept, in dem zunächst eine datenlose, semiquantitative, also kategorisierte Einschätzung von Nutzen, Aufwand und Risiko ermittelt wird, um diese Parameter für die jeweilige ML-Anwendung zu bewerten.

Für die erste Stufe wurde im Projekt der ML4FW-Fragebogen erstellt, der durch die Abfrage der Präferenzen, Umstände und Voraussetzungen des Anwenders eine personalisierte Auswertung von Informationen aus einer hinterlegten Wissensbasis vornimmt. Auf diese Weise kann der Anwender ohne großen Aufwand eine erste Einschätzung zu den im Fragebogen hinterlegten Use Cases erhalten und auf Basis einer erstellten Übersicht entscheiden, welchen Use Case er tiefergehend evaluieren möchte.

In der zweiten Stufe kann der Nutzer dann auf Grundlage seiner Daten eine genauere Auswertung des identifizierten Use Case durch ML-Experten vornehmen lassen, um zu einer finalen Entscheidung zu gelangen.

Die Ergebnisse der wissenschaftlichen Begleitung sind in den hinterlegten Experteneinschätzungen zu 19 bewerteten ML Use Cases in den Kategorien Instandhaltung Hausstationen, Instandhaltung Rohrleitungsnetz, Wärmebedarfsprognosen, Betriebsstrategien Wärmenetz und Betriebsstrategien Hausstationen zusammengefasst. Der für die Personalisierung dieser Einschätzungen konzipierte ML4FW-Fragebogen wurde in eine Python-Anwendung überführt, die für die Use-Case-Einschätzung die folgenden Schritte durchläuft:

1. Kategorieauswahl
2. Gewichtung globaler Kriterien
3. Gewichtung lokaler Kriterien
4. Beantwortung kategorieübergreifender Fragen
5. Kategoriespezifische Fragen zum Risiko
6. Kategoriespezifische Fragen zu Daten und Aufwand
7. Auswertung und Visualisierung der Ergebnisse

Mit der Anwendung wurde zum ersten Mal überhaupt eine für Nutzer direkt einsetzbare Methode entwickelt, um ML Use Cases im Fernwärmesystembetrieb zu bewerten. Neuartig ist dabei der Ansatz einer datenlosen Einschätzung, die von potenziellen Anwendern schnell und ohne detailliertes ML-Hintergrundwissen vorgenommen werden kann. Ergebnis der Anwendung ist eine erste semiquantitative Abschätzung von Nutzen, Aufwand und Risiko unterschiedlicher ML Use Cases. Damit bietet der ML4FW-Fragebogen Akteuren aus dem Fernwärmesystembetrieb eine neuartige Möglichkeit zur persönlichen Einschätzung von ML Use Cases.

Um dieses Tool weiterzuentwickeln, sollte zukünftig eine breitere Erprobung der erstellten Bewertungsmethode durch weitere Akteure aus dem Bereich des Fernwärmesystembetriebs durchgeführt werden. Durch das gezielte Einsammeln von Feedback können eine weitere Verbesserung und eine höhere Nutzerfreundlichkeit des Fragebogens sichergestellt werden.

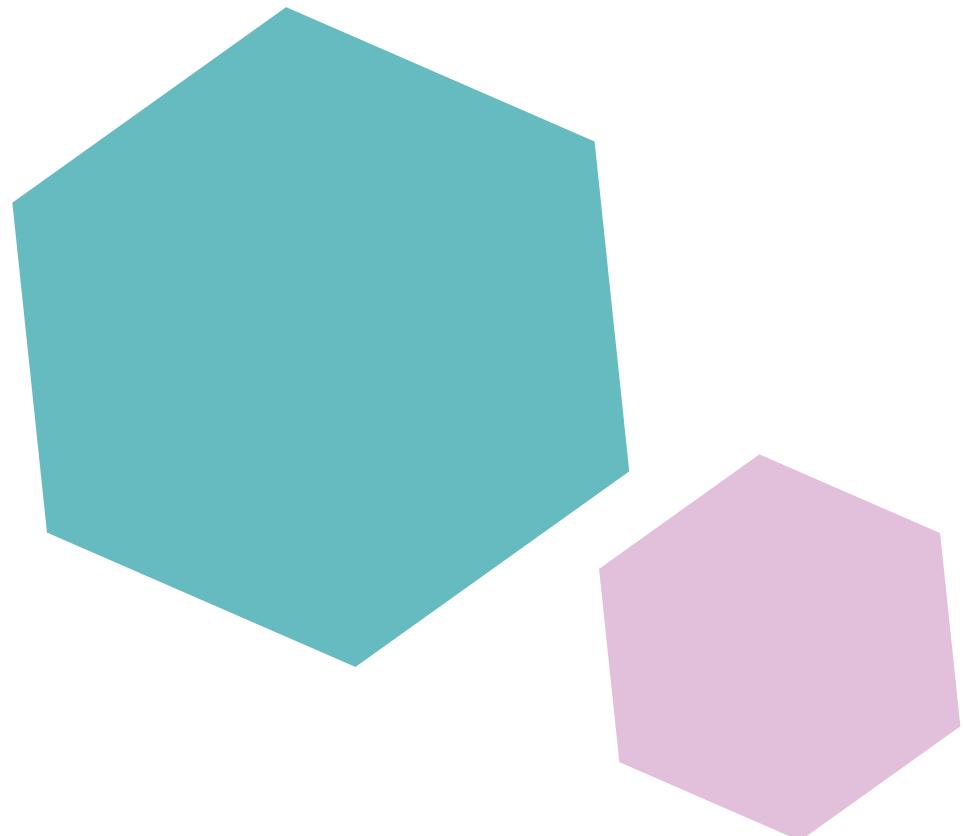
Darüber hinaus gibt es weitere Ansätze, um das Bewertungskonzept und den damit einhergehenden Mehrwert zu steigern: Weitere Expertinnen und Experten sollten eingebunden werden und durch konkretisierte, leichter einzuschätzende Kriterien die Beantwortbarkeit erhöhen. Ergänzend sollte der Fragebogen um

die Kategorie „Betrieb der Wärmeerzeugung“ erweitert werden, da hier erhebliche Potenziale für ML Use Cases vermutet werden und zugleich der Blick auf den Betrieb ganzer Fernwärmesysteme geöffnet wird. Schließlich gewinnt die Auswertung des ML4FW-Fragebogens an Schärfe und Aussagekraft, wenn zusätzliche Umsetzungsprojekte von ML Use Cases im Fernwärmesystembetrieb vorliegen und ihre Ergebnisse öffentlich verfügbar sind.

Zusammenfassend zeigt das Gesamtprojekt ML4FW, dass datenbasierte Optimierungen mittels maschinellen Lernens im Fernwärmebetrieb signifikante Effizienz- und damit auch Kostenvorteile bieten können. Die im Projekt entwickelte Bewertungsmethode erleichtert den Einstieg in die Anwendungen von ML, indem sie einen systematischen, vergleichenden Blick

auf verschiedene Use Cases ermöglicht und ihre Priorisierung nach klaren Kriterien (z. B. Wirkung, Umsetzbarkeit, Datenlage, Reifegrad) unterstützt. Herausforderungen bestehen weiterhin bei der Übertragbarkeit der entwickelten Methoden auf andere Gebäude- und Systemtypen sowie in der fortlaufenden Schärfung der Bewertungslogik zur Identifikation weiterer Potenziale. Zukünftige Forschungsarbeiten sollten sich darauf konzentrieren, diese Methoden zu verfeinern, und auf eine breitere Anwendung sowie eine entsprechende Skalierung in der Praxis abzielen.

Die Trainings- und Optimierungs-Pipeline sowie die Unterlagen zur Bewertungsmethode werden unter <https://github.com/AEFDI/ML4FW> veröffentlicht.



1. Hintergrund

Wie viele andere Industrieländer hat sich auch Deutschland mit dem Pariser Klimaschutzabkommen verpflichtet, bis zum Jahr 2045 klimaneutral zu werden. Um dieses ehrgeizige Ziel zu erreichen, müssen in allen Sektoren die Emissionen von sogenannten Treibhausgasen reduziert und schließlich vermieden werden. Besonders der Energiesektor steht hier in der Pflicht.

Im Allgemeinen liegt der Fokus für die zu ergreifenden Maßnahmen in der öffentlichen Wahrnehmung auf der Transformation im Stromsektor. Durch die Zunahme der Stromerzeugung aus erneuerbaren Energiequellen konnte im Stromsektor schon viel erreicht werden. Doch über 50 Prozent des deutschen Endenergieverbrauchs entfallen auf den Wärmebereich. So ist diesem Verbrauchssektor für die Erreichung der oben beschriebenen Ziele besondere Beachtung zu schenken. Die Transformation der gesamten Wärmeinfrastrukturen und die Umsetzung der Wärmeversorgung von Gebäuden stellen einen wichtigen Schwerpunkt für die Umsetzung der Wärmewende dar. Dem Ausbau der leitungsgebundenen Wärmeversorgung und der Umsetzung der Wärmeerzeugung in den Wärmenetzen kommen eine besondere Relevanz zu.

1.1 Relevanz der Fernwärme für die Energiewende

Die Zukunft der urbanen Wärmeversorgung liegt in der intelligenten Vernetzung von Erzeugung, Verteilung und Verbrauch – und genau hier setzt die Fernwärme als leistungsfähige Infrastruktur an. Die besondere Stärke der Fernwärme besteht in ihrer Fähigkeit, sowohl konventionelle als auch erneuerbare Energiequellen effizient zu bündeln und großflächig bereitzustellen. Mit dem Rohrsystem der Fernwärme ist es möglich, Abwärme oder Wärme aus unterschiedlichen Quellen einzusammeln und über dieses Rohrsystem den angeschlossenen Kunden zur Verfügung zu stellen. Dadurch können ganze Stadtquartiere, Industrieareale und öffentliche Einrichtungen mit klimafreundlicher Wärme versorgt werden.

Mit Blick auf die Klimaschutzziele der Bundesregierung und die Vorgaben des europäischen Green Deal ist eine tiefgreifende Transformation der Fernwärmesysteme erforderlich. Der Ausstieg aus Kohle und perspektivisch auch aus Erdgas macht es notwendig, fossile Wärmeerzeugung durch erneuerbare Alternativen wie mit Grünstrom betriebene Großwärmepumpen, Solarthermie, Geothermie oder industrielle Abwärme zu ersetzen. Auch im Gebäudeenergiegesetz (GEG), wo ein Anteil von 65 Prozent erneuerbarer Energien für den Betrieb von neu eingebauten Wärmeerzeugern in Wohngebäuden vorgeschrieben wird, oder im Wärmeplanungsgesetz (WPG), in dem die Verpflichtung zur Wärmeplanung von Kommunen geregelt ist, bei der der mögliche Ausbau der FernwärmeverSORGUNG mit betrachtet wird, wird die Relevanz der Fernwärme für die zukünftige Wärmeversorgung herausgestellt. Die Fernwärme bietet für den Umbau der Wärmeversorgung eine ideale Infrastruktur, denn sie erlaubt eine flexible Einbindung und Verteilung unterschiedlichster Energiequellen.

Ein Schlüsselfaktor für die erfolgreiche Dekarbonisierung ist die Steigerung der Netzeffizienz, insbesondere durch die Absenkung der System- und Rücklauftemperaturen. Hohe Rücklauftemperaturen führen zu unnötigen Netzverlusten und schränken die Integration von Niedertemperaturquellen (wie Abwärme oder Wärme aus Solaranlagen oder Wärmepumpen) erheblich ein. Ein nicht optimierter Betrieb führt gegebenenfalls zu einem höheren Brennstoffeinsatz, sprich unnötigen CO₂-Emissionen. Die Optimierung der Hausstationen und der sekundärseitigen Anlagen ist für die Netzeffizienz essentiell, um den Wärmebedarf effizient und möglichst verlustarm zu decken. Die im Projekt ML4FW eingesetzten Methoden des maschinellen Lernens adressieren genau diese Herausforderung, indem sie eine automatisierte, kontinuierliche Anpassung der Reglerparameter an die aktuellen Betriebsbedingungen ermöglichen.

Fernwärme ist damit nicht nur ein technisches Bindeglied zwischen Erzeugung und Verbrauch, sondern auch ein Innovationsfeld für die Entwicklung neuer, intelligenter Steuerungs- und Optimierungslösungen, die einen wesentlichen Beitrag zur Erreichung der Klimaziele leisten können.

1.2 Digitalisierung in der Fernwärme

Ein wesentlicher und notwendiger Schritt zur Umsetzung der Strategien zur Dekarbonisierung des Wärmesektors ist eine umfassende Digitalisierung in der Fernwärme. Die Digitalisierung kann zur Dekarbonisierung der Fernwärme beitragen, beispielsweise durch (vgl. dena 2024):

- **Effizienzsteigerung:** Durch den Einsatz intelligenter Steuerungssysteme kann der Energieverbrauch optimiert und Verluste können minimiert werden.
- **Integration erneuerbarer Energien:** Digitale Systeme erleichtern die Integration und Steuerung erneuerbarer Energiequellen wie Solar- und Geothermie.
- **Datenanalyse:** Durch die Analyse von Verbrauchsdaten können Schwachstellen identifiziert und gezielte Maßnahmen zur Reduktion von CO₂-Emissionen ergriffen werden.
- **Vorausschauende Wartung:** Digitale Überwachung ermöglicht eine proaktive Wartung, wodurch Ausfälle und ineffiziente Betriebszustände vermieden werden.
- **Nutzerverhalten:** Smarte Technologien können das Nutzerverhalten beeinflussen und zu einem bewussteren Umgang mit Energie führen.

Insgesamt stärkt die Digitalisierung die Effizienz und Flexibilität des Fernwärmesektors, fördert die Integration nachhaltiger Energiequellen und sorgt für eine zuverlässige Wärmeversorgung, was sowohl ökologisch als auch ökonomisch von Vorteil ist.

1.3 Potenziale für Machine Learning in der Fernwärme

Eine spezielle Möglichkeit für weitere Effizienzsteigerungen im Fernwärmebetrieb bietet die Digitalisierung beispielsweise durch die Analyse großer Datenmengen mittels moderner Algorithmen des Machine Learning (ML). Die daraus abgeleiteten Ergebnisse oder Entscheidungsgrundlagen versprechen eine Verbesserung des Wärmesystembetriebs. Neben dem in diesem Vorhaben fokussierten Anwendungsfall der Optimierung von Reglerparametern der Hausstationen (HAST) gibt es weitere Anwendungsfälle, wie detaillierte Wärmebedarfsprognosen für einen besser abgestimmten Anlagenfahrplan, der die Einbindung von Flexibilitäten innerhalb eines Fernwärmennetzes berücksichtigt und damit auch den Einsatz kostengünstiger erneuerbarer Energien für die Wärmebereitstellung steigern kann (Mbiydzenyuy 2021). Auch bei der vorausschauenden Wartung (Predictive Maintenance) kommen ML-Verfahren zum Einsatz, um Wartungsmaßnahmen frühzeitig zu identifizieren, die Versorgungsqualität aufrechtzuerhalten und kostenintensive Schäden durch eine rechtzeitige Reparatur zu vermeiden.

Im Fernwärmesektor eröffnen sich vielfältige Anwendungsmöglichkeiten für ML, die erhebliches Potenzial zur Steigerung der Effizienz von Fernwärmesystemen und ihres Betriebs bieten. Aktuell werden bereits unterschiedliche Use Cases für ML in der leitungsgebundenen Wärmeversorgung getestet. Sie decken jedoch bisher nur einen geringen Teil der möglichen Anwendungen in der Fernwärme ab. Der in diesem Projekt entwickelte Ansatz möchte einen Beitrag zum weiteren Einsatz von ML-Methoden im Fernwärmebetrieb liefern. Weiterhin wird in diesem Bericht auch eine Methode zur Bewertung und zum Vergleich von unterschiedlichen ML Use Cases vorgestellt, womit es möglich wird, von verschiedenen ML Use Cases zu lernen und diese Methoden auf die zum Teil sehr unterschiedlichen Fernwärmesysteme zu übertragen. Somit wird ein Ansatz zur Anleitung für einen wirksamen Einsatz der Technologie im Bereich der FernwärmeverSORGUNG geboten.

1.4 Use Case: Optimierung der Rücklauftemperaturen

Der Ausbau und die Transformation sowie die Dekarbonisierung der Wärmenetze unter anderem durch die Integration hoher Anteile erneuerbarer Energiequellen sind für die Erreichung der gesetzten Klimaschutzziele dringend geboten. Eine Absenkung der Systemtemperaturen in den Wärmenetzen eröffnet die Möglichkeit eines effizienten Anlagenbetriebs und der effizienteren und gegebenenfalls dezentralen Einbindung größerer Mengen erneuerbarer Wärme. Auch ökonomisch sind Maßnahmen zur Reduktion der Systemtemperaturen angezeigt, da sich ca. 0,5 bis 0,65 €/MWh·K einsparen lassen, was

EU-weit ein Einsparpotenzial von ca. 14 Mrd. €/a bei der Reduktion der Systemtemperaturen von 30 K ergibt (Averfalk et al. 2021). Eine effiziente Auskühlung des Rücklaufs erhöht darüber hinaus die sogenannte Spreizung, also die Temperaturdifferenz von Vor- und Rücklauf, was direkt in einer erhöhten Transportkapazität des Fernwärmesystems resultiert und Raum für weitere Anschlüsse ohne eine Netzverstärkung bietet.

Insbesondere im unsanierten Gebäudebestand ergeben sich technologische Herausforderungen, um auch bei reduzierten Vorlauftemperaturen eine ausreichende Wärmeversorgung sicherzustellen. In Abhängigkeit von der angestrebten Höhe der Absenkung der Netzzvorlauftemperatur können in Bestandsgebäuden Probleme auftreten: Die benötigte Heizleistung lässt sich möglicherweise durch das Heizungssystem nicht vollständig bereitstellen oder das bestehende Temperaturniveau reicht nicht aus, um die Raumheizlast über die vorhandenen Wärmeübergabesysteme zu decken. Zudem muss sichergestellt sein, dass die sekundärseitig erreichbaren Temperaturen nach der Absenkung für die hygienische Trinkwarmwasserbereitung ausreichen. Eine erste Lösungsstrategie ist die Beseitigung von fehlerhaften Ausführungen oder falschen Einstellungen der Anlagentechnik, um eine zwischen dem FernwärmeverSORGUNG und dem Kunden in den Technischen Anschlussbedingungen (TAB) vereinbarte Rücklaufauskühlung zu realisieren. Schon die Beseitigung von Fehlern an einer geringen Anzahl von Gebäudesystemen hat einen großen Effekt auf die Effizienz eines Wärmenetzes (Schmidt 2023).

Um diese Lösungsstrategie erfolgreich umzusetzen, ist der einwandfreie Betrieb aller Hausstationen essenziell. Neben der Prüfung der korrekten baulichen Umsetzung der Anlagen sind die Parameter der verbauten Stationen an die im speziellen Fall vorhandenen spezifischen sekundärseitigen Anlagen (Raumwärmeverteilung und Trinkwarmwasserbereitung) und die wärmenetzzitigen Gegebenheiten anzupassen. In der Praxis sind jedoch oft Stationen mit Reglern auf Werkseinstellung vorzufinden.

- ▶ Für die Realisierung einer effizienten und kostengünstigen leitungsgebundenen Wärmeversorgung müssen die Systemtemperaturen und im Besonderen die Rücklauftemperaturen gesenkt werden. Dies lässt sich im Wärmenetzbetrieb nur durch eine Optimierung der Hausstationen mit den sekundärseitigen Anlagen erreichen. Dazu sind die Betriebsparameter der Regler der Stationen jeweils optimal an die aktuellen Betriebszustände anzupassen. Der Betrieb der Wärmenetze wird über eine Digitalisierung der Anlagen effizienter, was zu stabilen Wärmepreisen und zu einer günstigeren Wärmeversorgung führt.

1.5 Zentrale Bedeutung der Wohnungswirtschaft für die Fernwärme

Der Wohnungsbau und die Wohnungswirtschaft spielen eine zentrale Rolle für die Entwicklung und den Ausbau der Fernwärme in Deutschland. So ist die Wohnungswirtschaft in Deutschland der größte Abnehmer von Fernwärme. Besonders im Mietwohnungsbau ist Fernwärme weit verbreitet, da sie sich gut für die zentrale Versorgung ganzer Wohnanlagen eignet. Weiterhin ist die Wohnungswirtschaft ein entscheidender Akteur bei der Erreichung der Klimaziele. Durch die Umstellung der Gebäude auf eine FernwärmeverSORGUNG, insbesondere wenn diese aus erneuerbaren Energien oder Abwärme stammt, können große CO₂-Einsparungen erzielt werden. Dazu zählt auch, dass gerade für die Wohnungswirtschaft eine verlässliche, langfristige Wärmeplanung essenziell ist. Nur mit Planungssicherheit können Wohnungsunternehmen die notwendigen Investitionen in die Infrastruktur tätigen und die Mietpreise stabil halten. Fernwärme ist wartungsarm und bietet sowohl für Vermieter als auch für die Bewohnerinnen und Bewohner eine hohe Versorgungssicherheit und großen Komfort. Die Kosten sind in der Regel langfristig kalkulierbar.

Aufgrund der zentralen Rolle der Wohnungswirtschaft wurde für dieses Projekt zur Optimierung des Fernwärmebetriebs ein Partner aus der Wohnungswirtschaft, die Neubrandenburger Wohnungsbaugenossenschaft eG (Neuwoba), eingebunden und der Fokus auf die Optimierung der Hausstationen bei der WärmeverSORGUNG von Mietwohnungen gelegt.

Die Neuwoba beheizt ca. 90 Prozent ihres Bestands mit Fernwärme. Durch die Energiekrise in Verbindung mit dem Krieg in der Ukraine wurde deutlich, dass nicht nur die Wärmeerzeuger oder der Wärmetransport in den Netzen von entscheidender Bedeutung für den Energieverbrauch sind, sondern in ganz besonderem Maße auch die Verbraucher. Dazu zählen die Hausstationen (HAST) und natürlich auch die Mieterschaft.

Für die Neuwoba ist es entscheidend, einen besseren Überblick und mehr Informationen über die HAST zu erhalten – etwa darüber, ob alle HAST richtig konfiguriert sind, ob die Zirkulation in den Gebäuden optimiert läuft oder ob es auf der Abnehmerseite zu hohe Wärmeverluste gibt. Erste Bestandsaufnahmen mittels Excel oder handschriftlicher Tabellen stellen kein praktikables, dauerhaftes Mittel zur Optimierung der Verbraucherseite dar. So wurden Schritte zur Digitalisierung bzw. zur Erstellung von digitalen Zwillingen der HAST eingeleitet, was aus Sicht der Neuwoba einige Vorteile mit sich bringt, wie beispielsweise:

- Einstellung von Kennlinien/Heizzeiten/Warmwasser-temperaturen usw.
- Dauerhaftes Aufzeichnen aller Fühlertemperaturen
- Erkennen von Ausfällen oder Anomalien in der Regelung
- Besseres Reagieren auf Mieterbeschwerden
- Optimierungsmöglichkeiten mittels:
 - Machine Learning (ML)
 - Wettervorhersage
 - Einbinden von Konzepten zur vorausschauenden Wartung
 - Optimierung der Anschlusswerte durch Peak Shaving

Mit der Digitalisierung der HAST ist ein großer Informationsgewinn hinsichtlich des Heizungssystems auf der Verbraucherseite verbunden. Die Senkung des Energieverbrauchs kann in verschiedenen Fällen bis zu 30 Prozent betragen (Techem 2025). Mithilfe von KI- und ML-Methoden wird dauerhaft die für das Gebäude optimal benötigte Energieversorgung ermittelt. Aus der Sicht der Neuwoba ist die Fernwärme das richtige Mittel zur klimaneutralen Wärmewende. Voraussetzung dafür ist jedoch, dass zunächst die Verbraucherseite optimal eingestellt ist. Darauf aufbauend muss der Wärmetransport möglichst effizient und mit geringen Wärmeverlusten erfolgen. Erst dann lässt sich die tatsächlich benötigte Wärmeerzeugung sinnvoll bestimmen, um die Gebäude bedarfsgerecht zu versorgen. Ziel ist es, nur die notwendige Vorlauftemperatur zu erzeugen und auf Verbraucherseite eine möglichst niedrige Rücklauftemperatur ins Netz zu erreichen.

1.6 Einordnung des gewählten Use Case

Wie in Kapitel 1.4 beschrieben, ist die Reduktion der Rücklauftemperaturen ein für die Transformation der Fernwärme und der WärmeverSORGUNG entscheidender Schritt. Somit wurde für dieses Projekt die Zielstellung gewählt, die Anwendbarkeit und Effektivität von Methoden des maschinellen Lernens für das Auto- und Continuous-Commissioning von Regelgeräten an realen Fernwärme-Hausstationen mit dem Ziel der Reduktion der Rücklauftemperaturen zu demonstrieren. Unter Auto-Commissioning wird hier die automatisierte Anpassung von Reglerparametern, die sich zunächst in der Werkseinstellung befinden, an die individuellen Betriebsbedingungen des jeweiligen Gebäudes verstanden. Dies soll sicherstellen, dass eine optimale Regelung der HAST erreicht wird. Beim Continuous-Commissioning wird zudem eine kontinuierliche Anpassung der Reglerparameter an sich verändernde Betriebsbedingungen durchgeführt. Um diese Ziele zu erreichen, wurden im Rahmen des hier beschriebenen Projekts die Entwicklung, Umsetzung und Demonstration einer ML-Ops Pipeline¹ verfolgt. Diese Pipeline nutzt Messdaten der

¹ ML-Ops (Machine Learning Operations) ist ein Konzept, das zum Ziel hat, ML-Modelle über ihren gesamten Lebenszyklus hinweg im Betrieb weiterzuentwickeln, bereitzustellen, zu überwachen und kontinuierlich zu verbessern.

Regelgeräte sowie Verbrauchs- und Umgebungswerte, um die optimalen Reglerparameter zu berechnen und sie anschließend an die Regelgeräte zu übermitteln (vgl. Kapitel 2). Ein wesentlicher Vorteil dieser Herangehensweise ist, dass eine Optimierung der Parameter auf Basis gewonnener Daten erfolgt, für den sicheren Betrieb des Reglers dann jedoch keine permanente Datenverbindung benötigt wird. So lassen sich viele Probleme in der praktischen Anwendung vermeiden und ein störungsfreier Betrieb ohne Konnektivitätsprobleme kann gewährleistet werden. Durch die Anpassung der Reglerparameter wird die optimale Regelung von HAST gefördert und die Methode trägt zur Effizienzsteigerung und Nachhaltigkeit in der Wärmeversorgung bei.

1.7 Aufbau und Struktur des Entwicklungsprojekts

Das Vorhaben „ML4FW – Maschinelles Lernen für Fernwärme“ gliedert sich in zwei inhaltliche Schwerpunkte: zum einen in die Entwicklung und Erprobung des gewählten Use Case für den Einsatz von ML-Verfahren im Fernwärmesystembetrieb (wie in Projektteil 1 (Kapitel 2) beschrieben), zum anderen in die Entwicklung einer Methodik zur Bewertung von ML Use Cases in der Fernwärme, inklusive der wissenschaftlichen Begleitung bei der Erprobung des Use Case (wie in Projektteil 2 (Kapitel 3) beschrieben).

Diese beiden Schwerpunkte werden im Folgenden weiter ausgeführt und detailliert erörtert. Die Schwerpunkte wurden von den Konsortialpartnern im engen Austausch bearbeitet.

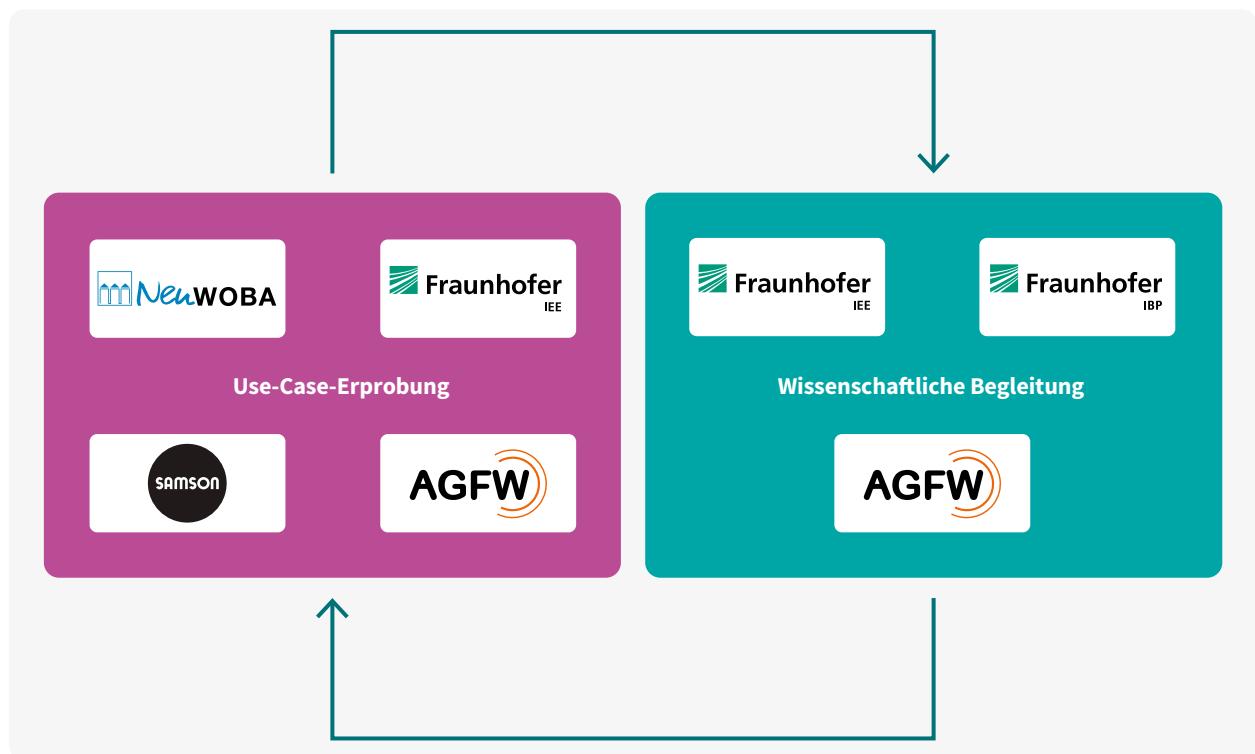


Abbildung 1: Konsortium und Zusammenarbeit in den beiden Teilvorhaben des Projekts

2. Projektteil 1: Umsetzung des Use Case „Optimierung von HAST-Reglerparametern“

Wie in Kapitel 1.6 beschrieben, werden in diesem Vorhaben an dem Anwendungsfall der automatischen Einstellung der Parameter von Regelgeräten in Hausstationen in der Fernwärmeversorgung die Anwendbarkeit und die Effektivität von Methoden

des maschinellen Lernens demonstriert. Für die Umsetzung wurde die in Abbildung 2 dargestellte Gesamtsystemarchitektur gewählt. Die einzelnen Schritte werden im Folgenden ausführlich beschrieben.

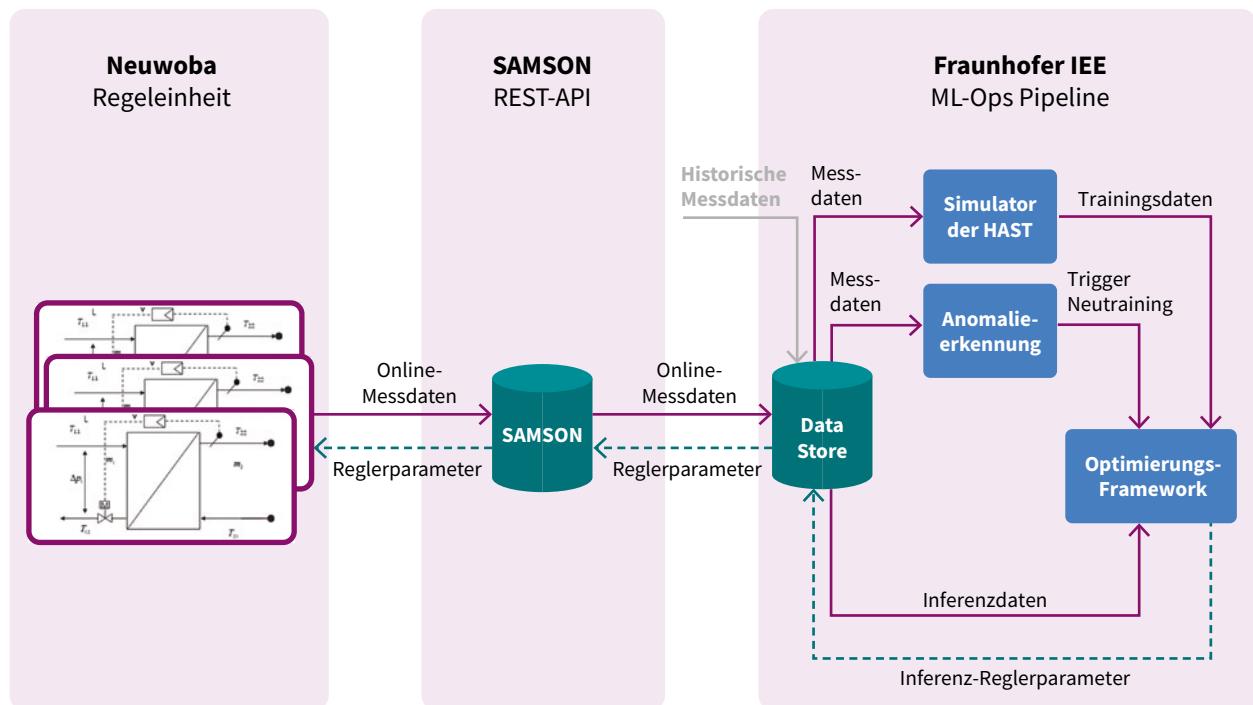


Abbildung 2: Gesamtsystemarchitektur für die Realisierung des Use Case

2.1 Schaffung der Datengrundlage für das Projekt

Die Erfassung der für das Vorhaben benötigten Daten aus den Hausstationen der Umsetzungsgebäude erfolgte automatisiert über digitale Verbrauchszähler, Regler und Netzpumpen, die an das System SAM DISTRICT ENERGY angebunden sind. Die Auslesewerte dieser Geräte werden in festlegbaren Intervallen (z. B. stündlich, täglich, monatlich) erfasst und über Gateways an die zentrale Plattform SAM DISTRICT ENERGY übertragen.

Im Rahmen des Projekts lag der Fokus der Datenerfassung auf den Liegenschaften der Neuwoba Petrosawodsker Straße 66-72 und Petrosawodsker Straße 42-48 in Neubrandenburg. Eine detaillierte Beschreibung der Liegenschaft Petrosawodsker Straße 66-72 erfolgt in Kapitel 2.4. Beide Liegenschaften besitzen ein identisches Anlagenschema der Heizungssysteme und befinden sich in örtlicher Nähe zueinander. Die Anlagenschemata werden für die Dokumentation ebenfalls in SAM DISTRICT ENERGY beschrieben. So ist die Information, wie die einzelnen Komponenten eines Heizungssystems (z. B. Zähler, Pumpen, Regelungen) miteinander verschaltet sind, jederzeit abrufbar. Die Wahl und die Ausgestaltung des Anlagenschemas wirken sich direkt auf die Art, Anzahl und Qualität der im Portal verfügbaren Datenpunkte aus. Das einheitliche Anlagenschema ermöglicht eine Übertragbarkeit bzw. Vergleichbarkeit der

Daten der Liegenschaften. Die Daten aus der Petrosawodsker Straße 66-72 wurden vor allem für die Implementierung der Algorithmen genutzt, während jene der Petrosawodsker Straße 44-48 in erster Linie für Validierungszwecke im Feldtest dienten.

Für die erforderlichen Simulationen und das ML-Training wurden folgende weitere Anforderungen an die Datenbasis im Rahmen des Vorhabens definiert:

1. Feingranulare historische Datensätze: Sie ermöglichen die Abbildung auch kurzzeitiger Warmwasser-Zapfvorgänge.
2. Auswahl relevanter Datenpunkte: Beinhaltet unter anderem Temperaturen, Stellsignale sowie Leistungswerte an Reglern und Wärmemengenzählern. Eine detaillierte Auflistung der verwendeten Datenpunkte befindet sich im Anhang in Tabelle 9.
3. CSV als Ziel-Dateiformat: Das benutzerfreundliche Format wird von Microsoft Excel, Python und MATLAB umfassend unterstützt.

Die Datensatzerstellung für die weitere Verarbeitung erfolgte seitens des Fraunhofer IEE durch die Extraktion der Daten aus der Plattform SAM DISTRICT ENERGY über verschiedene Ansätze:

1. Datenabruf über die REST-API von SAM DISTRICT ENERGY

Die Plattform SAM DISTRICT ENERGY stellt eine REST-API im OpenAPI-Format bereit, über die Daten automatisiert abgerufen werden können. Zur Authentifizierung muss ein Zugangs-Token übermittelt werden, wobei nur die Daten abgerufen werden, die für dieses Token sichtbar sind. Anhand der API-Beschreibung wurde ein Python-Client generiert, um den automatisierten Datenabruf zu realisieren. Die empfangenen JSON-Daten wurden anschließend in das gewünschte CSV-Format konvertiert. Dieser Ansatz ermöglicht flexibel konfigurierbare Anfragen in Bezug auf Datenpunkte und Auflösung und erlaubt zudem den Abruf aktueller Echtzeitdaten. Allerdings eignet sich dieser Weg weniger gut für den Abruf großer historischer Datensätze, da sowohl die Anzahl der Datenpunkte pro Anfrage als auch die Anfragelimits begrenzt sind.

2. Exportfunktion der grafischen Oberfläche von SAM DISTRICT ENERGY

Die grafische Nutzeroberfläche von SAM DISTRICT ENERGY unterstützt neben ersten visuellen Datenanalysen über eine Chart-Ansicht auch den CSV-Export. Dabei können Konfigurationen wie das Berechnen neuer Datenpunkte aus bestehenden Werten oder die gleichzeitige Darstellung von Werten verschiedener Geräte vorgenommen werden. Die exportierten Daten enthalten außerdem Meta-Informationen darüber, ob es sich um Roh-Messwerte oder zum Beispiel durch Interpolation berechnete Werte handelt.

3. Direkter Datenbank-Export seitens SAMSON

Dieser Ansatz kam im Fall des Ausfalls eines Reglers zum Einsatz, wenn die Plattformdaten nicht mehr verfügbar waren. Obwohl die als CSV vorliegenden Rohdaten erst vorverarbeitet werden mussten – etwa hinsichtlich der Einheitenkonvertierung oder der Kategorisierung –, stellte dies eine wertvolle Backup-Lösung dar.

Alle dargestellten Methoden fanden im Projektzeitraum Anwendung. Für jedes Verfahren wurden spezifische Vorverarbeitungsalgorithmen entwickelt, um sämtliche Ausgangsdatenformate in ein einheitliches Zielformat zu überführen.

Die Erstellung der Datensätze gestaltete sich teilweise herausfordernd und spiegelte die typischen Probleme bei der fortschreitenden Digitalisierung von Regel- und Messsystemen wider:

Ausstehende Hardware-Anbindung

Der Wärmemengenzähler (WMZ) wurde im November 2024 angebunden, sodass ein vollständiger Datensatz für die Simulationen erst erstellt werden konnte, nachdem ausreichend Daten vom neuen Wärmemengenzähler erfasst worden waren.

Ausfall/Neuanschluss von Geräten

Am Rande des Vor-Ort-Treffens am 26.11.2024 in Neubrandenburg wurde festgestellt, dass einige Messergebnisse nicht plausibel waren, was eine Neuinbetriebnahme der Messtechnik erforderlich machte. Daher wurde der Regler am 06.12.2024 mit einer angepassten Konfiguration neu in Betrieb genommen, was zu Lücken in den verfügbaren Daten führte.

Aus diesem Grund und aufgrund ähnlicher Außentemperaturen wie im November wurde der Zeitraum für die Simulationsdaten auf Anfang Dezember bis Mitte Januar festgelegt. Ein finaler Datensatz mit den gültigen Daten des Reglers und des WMZ für den Zeitraum 06.12.2024 bis 13.01.2025 konnte erfolgreich exportiert werden.

Nach dem Austausch eines Gateways kam es zu einer unvollständigen Konfiguration bei einem Wärmemengenzähler. Dies führte zu einer Datenlücke bei den WMZ-Daten im Zeitraum 26.02.2025 bis 28.03.2025. Da dieser Zeitraum den Feldtest mit geplantem Beginn am 17.02.2025 einschloss, konnten die Daten zur Feldtest-Auswertung erst ab dem 28.03.2025 vollständig erhoben werden. Um die Datenbasis für den Feldtest zu erweitern konnten zusätzlich Messdaten für den Zeitraum 24.11.2025 bis 15.12.2025 gewonnen werden.

Perioden verminderter Datenqualität

Konnektivitätsprobleme führten zu zeitweilig eingeschränkter Messqualität. Zwischen dem 26.01.2025 und 26.02.2025 traten Störungen bei der Verbindung zwischen dem Gateway sowie dem Regler und dem Wärmemengenzähler der Liegenschaft auf. In diesem Zeitraum wurden statt minütlich nur sporadisch Werte an SAM DISTRICT ENERGY übertragen, sodass dieser Zeitraum für die weitere Verarbeitung und Auswertung nicht berücksichtigt werden konnte.

Fehlende Sensoren

Das Verhalten der in der Anlage verbauten Pumpen wurde nicht ausreichend messtechnisch erfasst, sodass der Massenstrom sekundärseitig nicht bekannt war. Auch für die Auswertung des Feldtests relevante Größen wie beispielsweise die tatsächliche Raumtemperatur war nicht bekannt. Für die Simulation stand jedoch die Rücklauftemperatur im Sekundärheizungskreis zur Verfügung.

Fehlende Isolation einzelner Datenpunkte

Da die WMZ-Daten sowohl die Heizleistung für die RaumwärmeverSORGUNG als auch die Warmwasserzapfungen abbilden, wurden die Daten nachträglich um die Trinkwarmwasser-Zapforgänge bereinigt, um so nur die Raumheizung betrachten zu können. Dies erfolgte durch die gleichzeitige Betrachtung der WMZ-Daten und des Zustands der Speicherladepumpe aus den Reglerdaten. Die Ersatzwerte in Zeiträumen, in denen die Speicherladepumpe aktiv war, wurden durch Interpolation ermittelt, um das langsame Schließen des Heizkreises durch die konfigurierte Inversregelung des Reglers abzubilden. Zudem wurde in dem Datensatz ein „Marker“ hinterlegt, der es auch im Nachhinein ermöglicht, festzustellen, an welchen Stellen die Bereinigung stattgefunden hat.

Eingeschränkte Nutzbarkeit bestimmter Zeiträume

Um die Qualität der optimierten Reglerparameter zu evaluieren, mussten zusätzliche Prüfungen durchgeführt werden, um sicherzustellen, dass die Außentemperaturen während der Auswertung den Bedingungen der Datenerfassung entsprachen.

Trotz dieser Herausforderungen konnten hinreichend nutzbare Datensätze für die nötigen Simulationen, das ML-Training und die Feldtest-Auswertung erstellt werden. Die detaillierten Verfahren zur weiteren Implementierung der Modelle werden in den folgenden Kapiteln 2.2 und 2.3 erläutert, die Ergebnisse des Feldtests werden in Kapitel 2.5 dargestellt.

2.2 Aufbau eines Simulationsmodells für die untersuchten Anlagen

Die erhobenen Messdaten bildeten die Grundlage für die Modellierung und die Simulation der HAST der Liegenschaft Petrosawodsker Straße 66-72. Diese hatten das Ziel, die Rücklauftemperatur der Liegenschaft in das Wärmenetz in Abhängigkeit von der Parametrierung der Heizkurve des Reglers der HAST simulativ abzubilden, um so einen Trainingsdatensatz für die ML-Modelle zu erzeugen. Zunächst wurden die Messdaten in MATLAB eingelesen und vorprozessiert. Hierbei erfolgte neben der Extraktion der Parameternamen und Einheiten eine Interpolation auf einen äquidistanten 1-minütigen Zeitvektor, um die leicht variierenden Zeitstempel der gemessenen Daten zu harmonisieren.

Im Vorfeld der detaillierten Simulation wurde analysiert, welche Heizkörper in der Liegenschaft installiert sind und ob die vorhandenen Flächen eine Reduktion der Rücklauftemperatur ermöglichen. Die Untersuchung der Heizlast des Gebäudes im Vergleich zur Kapazität der Heizkörper ergab, dass die Liegenschaft aufgrund der großzügig dimensionierten Heizkörper gut für die durchzuführenden Untersuchungen im Projekt geeignet war. Durch großzügig oder gegebenenfalls auch mehr als ausreichend dimensionierte Heizkörper besteht die Möglichkeit, durch die Anpassung des Durchflusses durch das Heizungssystem niedrige Rücklauftemperaturen zu erzielen, was in diesem Vorhaben untersucht und erreicht werden sollte.

Die Daten des WMZ umfassen, wie oben bereits beschrieben, sowohl die Heizwärmemengen als auch die des Trinkwarmwassers (TWW). Nach Erhalt der WMZ-Daten musste zunächst eine geeignete Methodik zur Abschätzung der Wärmebedarfe für das TWW auf Basis der Ein- bzw. Ausschaltzeitpunkte der TWW-Pumpe entwickelt werden. Anschließend konnten die Heizleistungen durch Subtraktion dieser Daten ermittelt werden.

Aufbauend auf den in MATLAB verarbeiteten Daten wurden die HAST und das Gebäude in Simulink (Mathworks 2025a) unter Verwendung von Simscape (Mathworks 2025b) modelliert. Eine Herausforderung dabei war, dass der sekundärseitige Massenstrom nicht bekannt war und von der sekundärseitigen Pumpe nur der Zustand (Ein/Aus) erfasst wird. Da die gebäudeseitige Rücklauftemperatur, neben weiteren Faktoren, unter anderem auch vom Massenstrom abhängig ist, war eine Abschätzung dieser Werte nötig. Sie wurde anhand einer vereinfachten Modellierung der Sekundärseite, bei der das Gebäude als ein Raum mit einem Heizkörper betrachtet wird, durchgeführt. Daraus ergibt sich ein Gleichungssystem, das die genannten Abhängigkeiten implizit beschreibt. Um dieses zu lösen, kam der numerische Solver „daessc“ von Simscape zum Einsatz.

Abbildung 3 zeigt eine schematische Darstellung des aufgebauten Simulationsmodells. Das Konzept der Modellierung ist es, dabei die Auswirkungen von Veränderungen der Reglerparameter (Violett) auf die primärseitigen Rücklauftemperaturen (Türkis) zu quantifizieren. Als weitere Eingangsgrößen werden die primärseitige Vorlauftemperatur, die primärseitige Wärmeleistung und die Außentemperatur verwendet (Hellviolett). Es handelt sich hierbei um Messdaten (vgl. Kapitel 2.1), die zeitabhängig und für jeden Simulationsdurchlauf identisch hinterlegt sind. Die physikalischen Zusammenhänge sollen dabei realitätsnah abgebildet werden. Der zuvor erläuterten Herausforderung mit dem gebäudeseitigen Massenstrom wird mithilfe des Hilfsreglers (Petrol) begegnet.

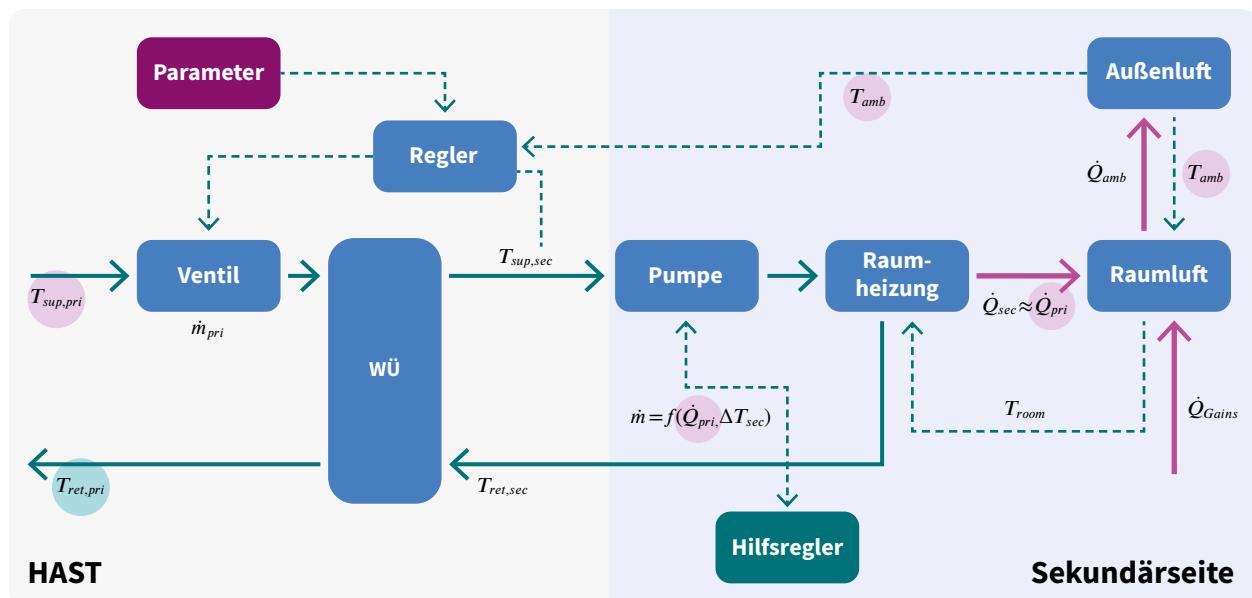


Abbildung 3: Schematische Darstellung des Simulationsmodells

Im Anschluss wurde das Simulationsmodell für die Liegenschaft parametriert und validiert. Es wurden Simulationen für verschiedene Reglerparametersätze durchgeführt und die Ergebnisse wurden in einem Datensatz für weitere Arbeiten bereitgestellt. Die Parametrierung des Modells basiert weitestgehend auf den verfügbaren Dokumenten zur HAST sowie zum Gebäude und seinen Heizkörpern. Parameter, die nicht dokumentiert sind, wurden abgeschätzt und mithilfe eines iterativen ADAM-Verfahrens (Adaptive Moment Estimation) optimiert, um die Messwerte der Rücklauftemperaturen möglichst genau abzubilden.

Die Validierung des Modells erfolgte zunächst getrennt für das HAST- und das Sekundärseitenmodell (vgl. Abbildung 3) und anschließend für das Gesamtmodell. Als Referenz dienten in allen Fällen die jeweiligen gemessenen Rücklauftemperaturen und es wurden nur Zeiträume verwendet, in denen keine Warmwasserbereitung erfolgte (vgl. Kapitel 2.1). Die Abweichungen von Simulation und Referenzmessdaten sind das Ergebnis der Validierung und können Tabelle 1 entnommen werden. Sie wurden als angemessen für die Fragestellung erachtet.

	HAST	Sekundärseite	Gesamtmodell
Mittlerer absoluter Fehler (MAE)	0,41 K	0,87 K	0,84 K
Mittlerer relativer Fehler (MAPE)	0,13 %	0,28 %	0,27 %

Tabelle 1: Ergebnis der Modellvalidierung

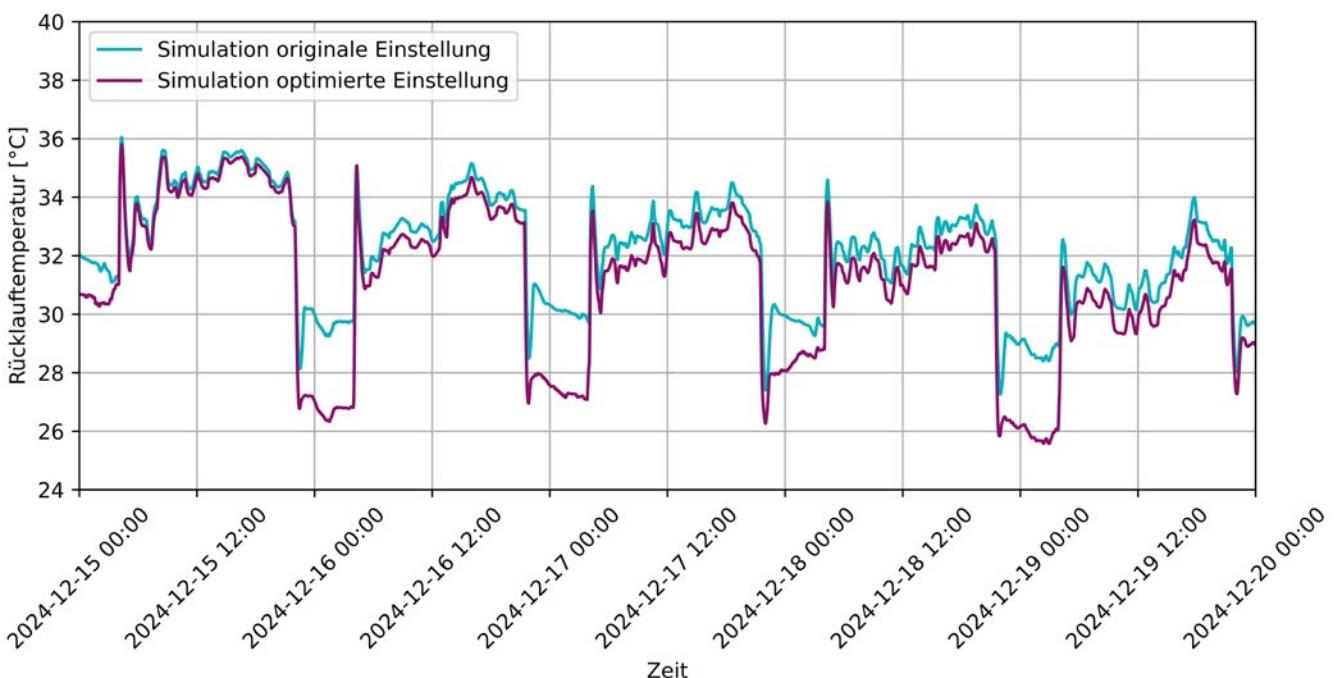


Abbildung 4: Beispielhafter Vergleich der simulierten Rücklauftemperaturen mit den vorherigen (original: $m = 0,7$, Niveau = 3,0) und den angepassten (optimiert: $m = 0,6$, Niveau = 0,0) Reglereinstellungen vom 15.12.2024 bis 20.12.2024

Das Modell wurde anschließend genutzt, um den Trainingsdatensatz für die maschinellen Lernverfahren zu generieren. Dafür wurden Simulationen für unterschiedliche Parameter der Heizkurve des Reglers durchgeführt und es wurde der Einfluss auf die Netzrücklauftemperaturen betrachtet (vgl. Abbildung 9). Die Parameter „Steigung“ (m) und „Niveau“ wurden über ihre maximalen sinnvollen Wertebereiche variiert und damit insgesamt 240 Simulationsdurchläufe durchgeführt. Die Ergebnisse zeigen, dass bei der Einstellung $m = 0,6$ und Niveau = 0 eine Absenkung der Rücklauftemperatur von durchschnittlich 0,9 K in der kältesten Periode des Messzeitraums möglich ist, ohne dass die übertragene Wärmeleistung reduziert wird. Über den gesamten Zeitraum liegt die durchschnittliche Absenkung in der Simulation

bei 0,46 K. Ein beispielhafter Vergleich der simulierten Rücklauftemperaturen mit originalen und optimierten Reglereinstellungen ist in Abbildung 4 dargestellt.

- ▶ Es wurde ein digitaler Zwilling von Hausstation und Gebäude erstellt und mit Wintermessdaten kalibriert; die Validierung ergab durchschnittlich 1 K Abweichung. Auf dieser Basis ließen sich 240 Heizkurvenvarianten in kurzer Zeit virtuell durchspielen. Die Ergebnisse ersetzten teure Vor-Ort-Tests und lieferten einen belastbaren Datensatz für das spätere ML-Training. Dadurch entstand die Grundlage für alle weiteren Schritte der Optimierung.

2.3 Erstellung der ML-Modelle und ihr Training

Im Rahmen des Projekts wurde ein datengetriebenes Surrogate-Modell entwickelt, das die Rücklauftemperatur der HAST in Abhängigkeit von externen Einflussgrößen und regelbaren Parametern vorhersagen kann. Das Modell soll die aufwendige physikalische Simulation (siehe Kapitel 2.2) der HAST ersetzen und die Bestimmung der Rücklauftemperatur in Abhängigkeit von den Reglerparametern deutlich beschleunigen. Somit ist es möglich, die Reglerparameter mit geringem Aufwand und automatisiert anzupassen.

Die im Vorhaben gewählte Modellarchitektur basiert auf einem 1D-Convolutional Neural Network (1D-CNN). Obwohl CNNs ursprünglich für die Verarbeitung von Bilddaten entwickelt wurden, haben sie sich in den letzten Jahren auch in der Analyse von Zeitreihendaten als äußerst leistungsfähig erwiesen (LeCun et al. 1998 & Zheng et al. 2014). Im Vergleich zu alternativen Architekturen wie Multilayer Perceptrons (MLPs) oder Long Short-Term Memory Networks (LSTMs) zeigte das 1D-CNN eine bessere Generalisierungsleistung bei gleichzeitig stabilerem Training. Die Architektur erlaubt es, lokale zeitliche Muster in der Eingangszeitreihe effizient zu erfassen. Dabei benötigt das Modell im Vergleich zu LSTMs deutlich weniger Rechenzeit, da es keine rekursiven Strukturen enthält. Das 1D-CNN analysiert zeitliche Eingangsreihen, indem es sogenannte Filter über die Zeitachse gleiten lässt und dabei lokale Muster wie Anstiege, Abfälle oder Periodizität erkennt. Dadurch kann das Modell wichtige Muster aus der Abfolge der Eingangsgrößen extrahieren, die für die Vorhersage der Rücklauftemperatur relevant sind, beispielsweise typische Reaktionsmuster auf bestimmte Wetterlagen oder Änderungen der Reglerparameter. Die Trainings- und Optimierungs-Pipeline wird unter <https://github.com/AEFDI/ML4FW/tree/main/Regleroptimierung> veröffentlicht.

Erstellung der Trainingsdatensätze

Das Training der ML-Modelle basierte auf einer Datengrundlage, die aus den Simulationen der HAST generiert wurde. Dabei wurden verschiedene Reglerparametereinstellungen systematisch variiert, um ein möglichst breites Spektrum möglicher Betriebszustände abzubilden. Insgesamt standen für das Training knapp 400.000 Datenpunkte sowie jeweils ca. 130.000 Datenpunkte für Validierung und Test zur Verfügung. Die Größe des Datensatzes hängt mit den in Kapitel 2.1 genannten Herausforderungen zusammen. Am Ende stand daher nur der Zeitraum vom 06.12.2024 bis 13.01.2025 als konsistente und nutzbare Trainingsgrundlage zur Verfügung.

Aus diesem Zeitraum wurden alle verfügbaren Zeitschritte mit Zusatzinformationen wie Tageszeit und Wochentag versehen. Sie wurden mittels Sinus- und Kosinus-Transformationen („Time

Embeddings“) kontinuierlich codiert. Zusätzlich wurden pro Zeitstempel sämtliche simulierten Kombinationen der Reglerparameter (z. B. Vorlauftemperaturbegrenzung, Rücklaufvorgabe) mit Umgebungsgrößen wie Außentemperatur und Wärmeanforderung kombiniert. Der finale Datensatz bildet somit für jeden Zeitpunkt eine vollständige Matrix aller simulierten Reglereinstellungen ab und ermöglicht die Bewertung ihrer Wirkung unter identischen äußereren Bedingungen. Um eine saubere Evaluierung zu ermöglichen, wurde beim Split in Trainings-, Validierungs- und Testdaten besonders darauf geachtet, dass keine zeitlichen Vorgriffe stattfanden (das heißt, der Testdatensatz enthielt keine „Zukunftsdaten“ aus Sicht des Trainings). Gleichzeitig war es notwendig, dass sowohl sehr kalte als auch vergleichsweise warme Tage in allen Teilmengen vertreten waren, um die Generalisierbarkeit des Modells zu sichern.

Evaluation des ML-Modells

Die Evaluation des Modells erfolgte anhand etablierter Regressionsmetriken (u. a. Mean Squared Error (MSE) und Mean Absolute Error (MAE)) sowie durch eine visuelle Überprüfung der plausiblen Systemantworten. Wie in Abbildung 5 zu sehen ist, konnte eine mittlere Abweichung der Rücklauftemperatur von rund 1 K erzielt werden. Auch wenn sich aufgrund der eingeschränkten Datenlage trotz Finetuning keine weitere Reduktion des Fehlers erzielen ließ, ergibt sich bei qualitativer Betrachtung ein plausibler zeitlicher Verlauf der Vorhersagen.

Methodik und Ergebnisse

Da die verfügbare Datenbasis für eine robuste Anwendung von Reinforcement Learning (wie zunächst geplant) nicht ausreichte, wurde alternativ ein zweistufiger Ansatz aus 1D-CNN und gradientenbasierter Optimierung gewählt. Reinforcement Learning ist im Vergleich zu anderen Machine-Learning-Verfahren besonders datenintensiv, da es viele Iterationen in einer explorativen Umgebung benötigt, um durch Rückmeldung in Form von Belohnungssignalen ein effektives Steuerungsverhalten zu erlernen. In unserem Fall standen jedoch nicht genügend unterschiedliche Datenpunkte zur Verfügung, um diesen Lernprozess sinnvoll zu unterstützen.

Daher wurde ein kombinierter Ansatz aus Surrogate-Modell und anschließender Optimierung gewählt. Dabei dient das trainierte Surrogate-Modell als differenzierbares Abbild der physikalischen Simulation. Auf dessen Basis können die optimalen Reglerparameter zur Minimierung der Rücklauftemperatur gesucht werden. Die gradientenbasierte Optimierung erfolgt, indem die Rücklauftemperatur als Zielfunktion formuliert wird, deren Gradienten bezüglich der Reglerparameter numerisch bestimmt werden. Auf Grundlage dieser Gradienten wird iterativ in Richtung des steilsten Abstiegs optimiert, bis ein lokales Minimum erreicht ist.

Zur Validierung der Optimierung wurde ergänzend ein Grid-Search durchgeführt, um das Ergebnis der Gradientenmethode abzusichern. Der betrachtete Suchraum umfasste:

- **Steigung**²: 0,5 bis 2,0 (in Schritten von 0,1)
- **Niveau**: 0,0 bis 7,0 (in Schritten von 0,5)

Die besten Ergebnisse hinsichtlich einer minimalen Rücklauftemperatur ergaben sich konsistent bei einer Steigung von 0,5 bis 0,7 und einem Niveau von 0,5.

Diese Werte decken sich mit den Tendenzen aus den physikalischen Simulationen und bestätigen somit die Qualität des datentreibenden Modells (vgl. Abbildung 5).

Trotz der vergleichsweise geringen Menge an Trainingsdaten konnte ein Modell entwickelt werden, das unter den gegebenen Randbedingungen realistische Vorhersagen liefert. Eine Generalisierung auf andere Witterungsverhältnisse oder Gebäudetypen ist jedoch nur eingeschränkt möglich. Die Prognosen sind daher mit einer gewissen Unsicherheit behaftet und bedürfen einer weitergehenden Validierung an realen Systemen.

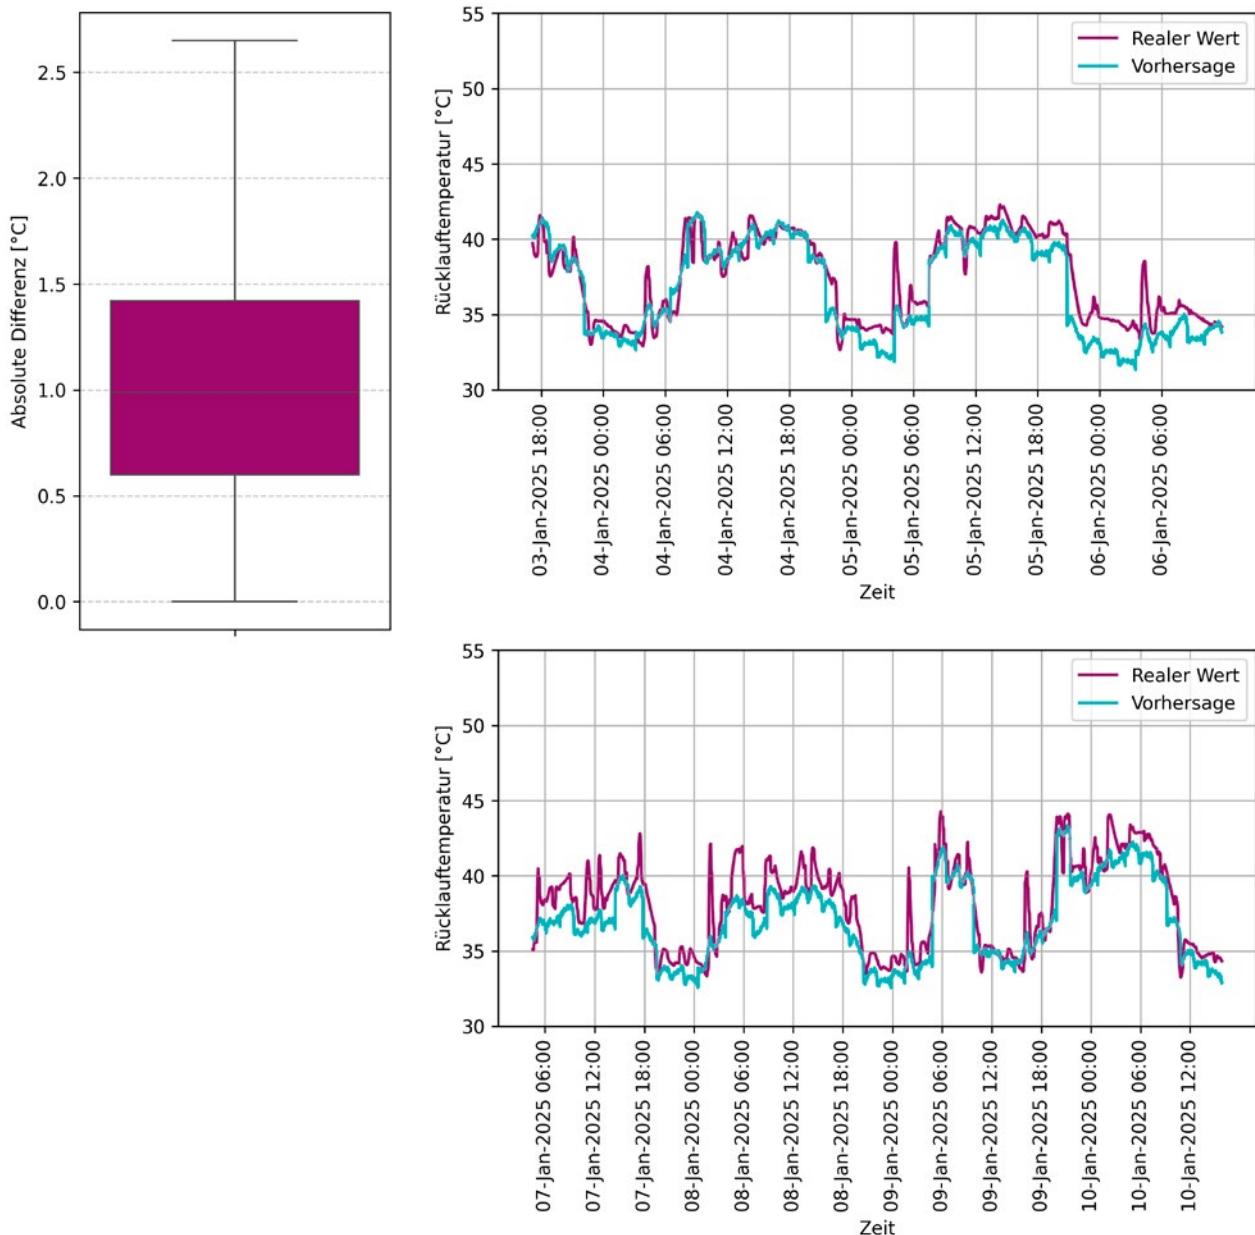


Abbildung 5: Vorhersagen des CNN auf dem Testdatensatz

Links: Boxplot der absoluten Fehler gemittelt über alle Zeitpunkte des Testdatensatzes, der dem Modell vollständig unbekannt ist.

Rechts: Tatsächliche Rücklauftemperatur vs. Vorhersage des Modells für eine Zeitreihe über ca. 3 Tage. In Violett ist die tatsächlich simulierte Rücklauftemperatur und in Türkis die Vorhersage des Modells zu sehen. Das Modell kann den Verlauf robust abbilden, stärkere Spitzen und Schwankungen werden zugunsten des mittleren Fehlers geglättet.

² Zur Erläuterung von „Steigung“ und „Niveau“ siehe Abbildung 9

Kontinuierliche Anpassung der Modelle durch ML-Ops Pipeline

Die ML-Ops Pipeline bildet die Grundlage für das wiederholte Training der ML-Modelle, was eine kontinuierliche Anpassung und Verbesserung der Modelle ermöglicht.

Im Datastore werden die Daten aus den Liegenschaften (vgl. Kapitel 2.1) zusammen mit den Daten, die als Ergebnisse aus der Simulation der HAST entstehen (vgl. Kapitel 2.2), gespeichert. Die Kommunikation mit dem Datastore erfolgt über eine REST-Schnittstelle. Die Authentifizierung für die Schnittstelle erfolgt über einen zentralen Single-Sign-on-Server (SSO) und nutzt das OAuth2-Protokoll. Lese- und Schreibberechtigungen können für die Kombination von einzelnen Nutzern oder Nutzergruppen und Buckets unterschiedlich gesetzt werden. Dadurch kann der Schutz von sensiblen Daten gewährleistet werden.

Die Daten können in einem beliebigen Dateiformat hochgeladen und gespeichert werden. Zusätzlich werden Metadaten zu den gespeicherten Daten hinzugefügt, um den weiterverarbeitenden Systemen, wie zum Beispiel dem ML-Trainingsmodul, eine Möglichkeit zu geben, die gespeicherten Daten zu filtern und für den jeweiligen Use Case passend abzurufen.

Ändert sich die Datenlage, sendet das ML-Trainingsmodul eine Anfrage an den Datastore, um die neuesten Daten zu erhalten. So können der Abstimmungsbedarf und manuelle Arbeitsschritte für wiederholte Trainingsläufe minimiert werden.

Der Datastore, der SSO-Server und die REST-Schnittstelle werden als containerisierte Services in einer Kubernetes-Infrastruktur betrieben. Diese Architektur bietet entscheidende Vorteile: Kubernetes verteilt die Container automatisch auf verfügbare Knoten und sorgt so für eine hohe Ausfallsicherheit; bei Lastspitzen kann es zusätzliche Instanzen starten und bei sinkender Last wieder abschalten, was Ressourcen spart. Rolling Updates und Rollbacks ermöglichen es, neue Versionen ohne Unterbrechung einzuspielen und bei Bedarf schnell zurückzusetzen. Zudem vereinfacht die einheitliche Orchestrierung das automatisierte Deployment, wodurch Änderungen schneller und kontrollierter in die Produktion gelangen können. Insgesamt erhöht Kubernetes damit die Skalierbarkeit, Verfügbarkeit und Wartbarkeit der genannten Komponenten.

- Aus den Simulationen entstand ein schlankes 1D-CNN-Surrogat, das Rücklauftemperaturen in Sekunden statt Stunden prognostiziert. Mit rund 1 K Vorhersagefehler bildet es das physikalische System hinreichend genau ab. Eine anschließende gradientenbasierte Suche bestimmt automatisch jene Heizkurvenparameter, die die Rücklauftemperatur minimieren. So wird aus vielen Simulationen ein handhabbares Optimierungswerkzeug. Das Ergebnis sind praxistaugliche Reglerwerte auf Knopfdruck.

2.4 Beschreibung der Umsetzungsgebäude für den Feldtest

Bei den für das Vorhaben gewählten Umsetzungsgebäuden der Neuwoba handelt es sich um typische WBS-70-Plattenbauten der DDR mit den Baujahren von 1979 bis 1985. Die Gebäude werden ausschließlich mit Fernwärme von den Neubrandenburger Stadtwerken versorgt.



Abbildung 6: Beispielgebäude in der Petrosawodsker Straße 66-72, Neubrandenburg

Die Datenerfassung und im Besonderen die Erstellung der ML-Modelle haben sich auf eines der Umsetzungsgebäude in der Petrosawodsker Straße 66-72 fokussiert. Das Gebäude wurde 1974 errichtet und ist eine WBS 70 C1-Variante. Das Gebäude hat eine Wohnfläche von 2.517 m² und umfasst 40 3-Raum-Wohnungen, die sich auf 5 Geschosse und 4 Hausaufgänge verteilen.

1996 erfolgte eine umfassende Modernisierung. Elektro- und Sanitärinstallation sowie die Heizungen in den Wohnungen, Hausstation, Fenster, Kellerdeckendämmung, Wohnungseingangstüren und Drempledämmung wurden erneuert. Das 1-Rohr-System blieb erhalten.

Um die Verbräuche des Wohnungsbestands zu reduzieren, werden jedes Jahr die alten 1-Rohr-Systeme gegen moderne 2-Rohr-Systeme ausgetauscht. Nachweislich wird der Gesamtverbrauch zwischen 20 und 30 Prozent reduziert (siehe Baugenossenschaft Wiederaufbau 2025). Im Jahr 2023 wurde in der Petrosawodsker Straße 66-72 das 1-Rohr-System zu einem 2-Rohr-System umgerüstet und die Haustation erneuert.

Die Heizungsvorlauftemperaturen konnten von 90 °C auf 55 °C bei Auslegungstemperatur gesenkt werden und das Gebäude ist auf der Heizungsseite Niedertemperatur-ready und für alternative Wärmeerzeuger wie Wärmepumpen geeignet. Es wurden 120 Heizkörper der Marke Buderus Logatrend C-Profil installiert und die 24 Stränge wurden erneuert.

Die Umsetzungsgebäude verfügen alle über einen Regler der Firma SAMSON und wurden als Pilot im Jahr 2022 mit einem Gateway ausgestattet, sodass ein digitaler Zwilling auf der SAMSON-Plattform SAM DISTRICT ENERGY aufgeschaltet werden konnte.

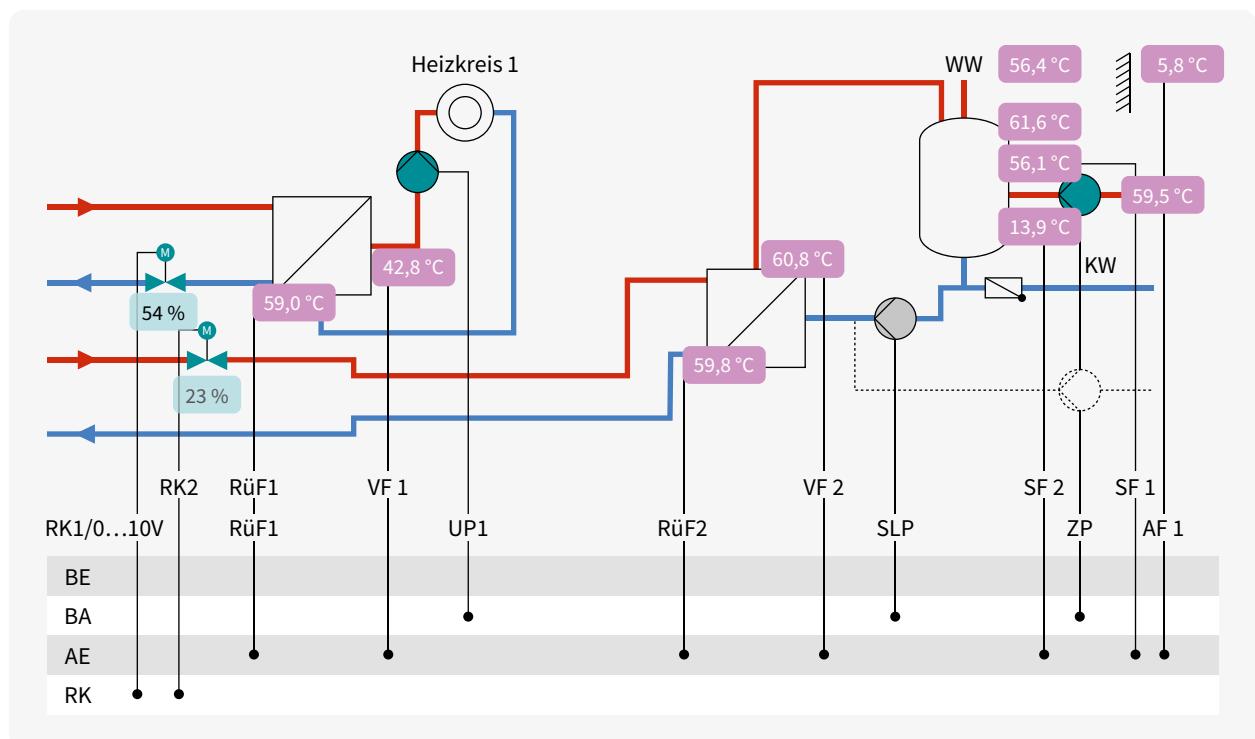


Abbildung 7: Schaltbild der Hausstation des Beispielgebäudes in SAM DISTRICT ENERGY

Die Gebäude haben jeweils 1 bis 2 Heizkreise sowie einen Trinkwasserspeicher. Die Heizung ist jeweils als Steigungskennlinie konfiguriert – hierdurch wird bei höherer Außentemperatur dem Gebäude weniger Wärme zur Verfügung gestellt (vergl. Abb. 9).

In den Beispielgebäuden sind SAMSON TROVIS Heizungs- und Fernheizungsregler der 5500-Serie verbaut. Hier werden unterschiedliche Typen eingesetzt, jedoch basieren alle auf derselben Plattform. In den Beispielgebäuden und so auch in der Petrosawodsker Straße 66-72 ist hauptsächlich der Typ 5578 installiert.

Diese Regler verwenden standardmäßig eine witterungsgeführte Regelung. Dabei misst ein Außentemperatursensor die aktuelle Temperatur und ermittelt über eine eingestellte Kennlinie die entsprechende Vorlauftemperatur, die der Regler dann für den entsprechenden Heizkreis ausregelt. Die Wahl der Kennlinie ist unter anderem abhängig von der gewünschten Raumtemperatur, der Heizungsart (Fußbodenheizung oder Radiator) und dem Gebäude selbst (Altbau, gedämmt etc.). Die Vorlauftemperatur wird nach folgender Gleichung berechnet:

$$Vorlauftemp = -Steigung \cdot (AT \cdot \frac{AT}{100} + AT - 24) - \frac{AT}{10} + 26 + 2 \cdot Steigung \cdot (Raumsoll - 20) + Niveau$$



Abbildung 8: Regler TROVIS 5578 der Firma SAMSON

- turnte Regelung verwendet. Als Parameter dieser Rechteilung dienen:

- Steigung
 - Niveau

Der „Raumsollwert Tag/Nacht“ ist auf Endkundenebene um die gefühlte Raumtemperatur anzuheben oder zu senken. Bei dem Standard-Raumsollwert von 20 °C gilt die Kennlinie 1:1.

Dieser Wert ist nicht Gegenstand der Parameteranpassung, da der Fokus auf der Optimierung der Parameter auf der Anlagenseite bei konstanten Bedingungen auf der Endkundenebene liegt. Der Verlauf der Kennlinie wird im Wesentlichen durch den Parameter „Steigung“ beschrieben. Mit dem Parameter „Niveau“ kann eine Parallelverschiebung der Kennlinie durchgeführt werden. Diese beiden Parameter beschreiben das anlagentechnische Verhalten der Hausstationen und werden in diesem Vorhaben durch die ML-Modelle angepasst. Sie sind Gegenstand des Auto- und Continuous-Commissioning in diesem Vorhaben.

► Der Praxistest wurde in einem modernisierten WBS-70-Mehrfamilienhaus mit 40 Wohneinheiten umgesetzt. Nach der Umrüstung auf ein 2-Rohr-System und der Installation eines SAMSON-Reglers samt Gateway wurde das Gebäude vollständig digital erfasst. Alle Mess-, Regel- und Verbrauchsdaten fließen minütlich in die Plattform SAM DISTRICT ENERGY. Dadurch konnten Simulation, Modelltraining und Live-Monitoring nahtlos ineinander greifen. Das Objekt dient nun als realer Demonstrator für das ML-gestützte Auto-Commissioning.

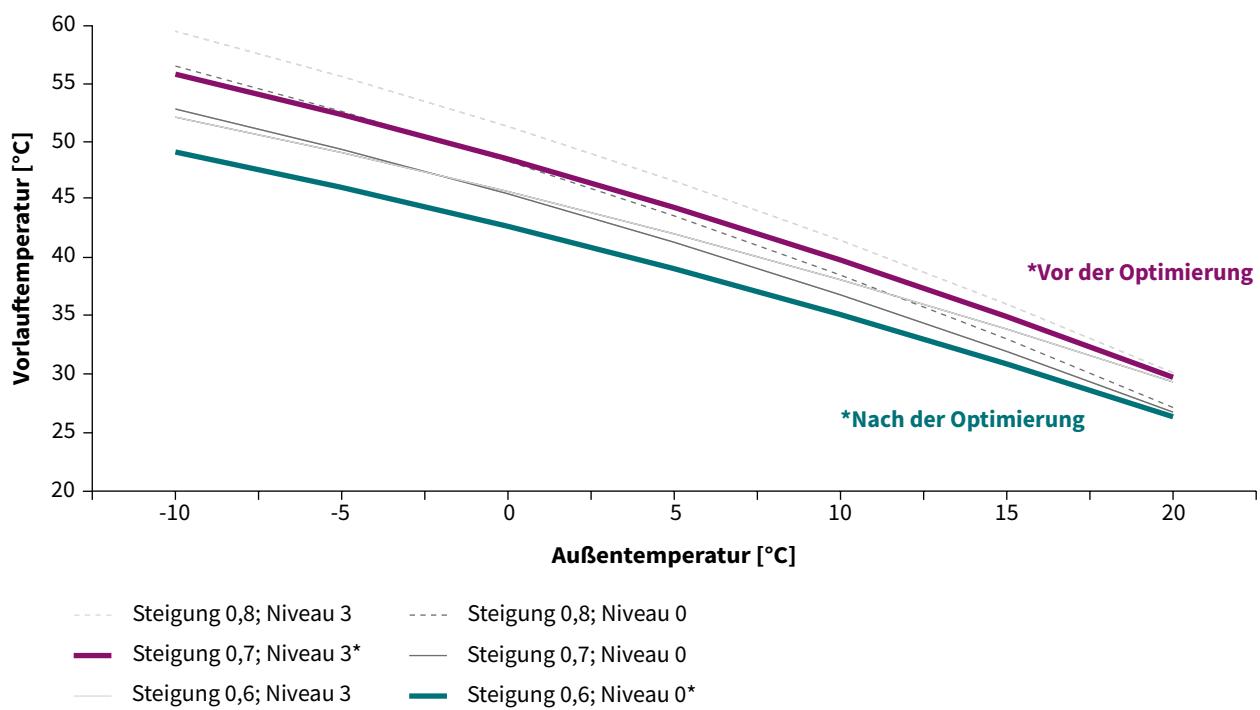


Abbildung 9: Steigungskennlinie des Reglers der Firma SAMSON entsprechend der Reglergleichung. Die Einstellungen vor und nach der Optimierung sind hervorgehoben.

2.5 Ergebnisse aus dem Feldtest

Der Feldtest wurde mit optimierten Reglerparametern an der Liegenschaft Petrosawodsker Straße 66-72 in zwei Perioden durchgeführt: vom 28.03. bis 14.04.2025 (Zeitraum 2, Frühjahr) sowie vom 25.11. bis 14.12.2025 (Zeitraum 3, Winter). Die für die Vergleiche notwendige Messperiode mit nicht optimierten Parametern der Regler (Zeitraum 1, Referenz) lag im Zeitraum 06.12.2024 bis 13.01.2025. Diese Messdaten wurden ebenfalls für das Modelltraining verwendet (vgl. Kapitel 2.1 und 2.3).

Für die Auswertung des Feldtests und zur Bewertung der Wirksamkeit der optimierten Reglerparameter wurden vier Leitfragen formuliert:

1. Reduktion der Rücklauftemperatur: Wurde für vergleichbare Betriebszustände die Rücklauftemperatur gesenkt?
2. Versorgungssicherheit: Wurde der Versorgungsauftrag erfüllt – wurde es im betrachteten Gebäude überall ausreichend warm?

3. Energieeffizienz: Wurde unter vergleichbaren Bedingungen weniger Wärme zugeführt?
4. Reduktion von Lastspitzen: Konnten durch die neue Einstellung kurzfristige Leistungs spitzen im Wärmebezug verringert werden?

Methodik der Datenauswertung

Zur Beantwortung der Fragestellungen wurde eine zweistufige Analysestrategie verfolgt:

1. Exemplarischer Tagesvergleich (witterungsbasiert)

Für einen detaillierten Vergleich wurden Vergleichstage mit ähnlicher Witterung aus allen drei Zeiträumen ausgewählt, da auf Grund der Datenlage nicht alle Einflussfaktoren außerhalb der Witterung, die ebenfalls einen großen Einfluss auf den Wärmebedarf haben können, berücksichtigt werden können. Das Vorgehen zur Auswahl basierte auf einem mehrstufigen Filterprozess:

1. Berechnung der Tagesmitteltemperatur (Kriterium 1). Für alle in der Datenbank verfügbaren Tage wurde zunächst die mittlere Außentemperatur berechnet. Diese diente als Grundlage für die Beurteilung der Witterungslage.
2. Für die Tage im Zeitraum 1 wurden in den Optimierungszeiträumen (Zeitraum 2 und 3) die Tage mit der ähnlichsten Tagesmitteltemperatur ausgewählt. Maßgeblich war das kleinste ΔT , wobei ΔT die Abweichung der Tagesmitteltemperaturen beschreibt. Dies ermöglicht eine hohe Vergleichbarkeit mit typischen Wintertagen

Kriterium 2: Prüfung der maximalen Tagesverlaufs differenz: Um zusätzlich sicherzustellen, dass sich nicht nur das Tagesmittel, sondern auch der Temperaturverlauf (z. B. tageszeitliche Schwankungen) ähnelt, wurde die maximale ΔT im Tagesverlauf als zweites Kriterium betrachtet. Nur Vergleichspaare mit geringer Differenz im Temperaturverlauf wurden ausgewählt. Das finale Ziel war es, Vergleichstage mit möglichst ähnlicher Außentemperatur und einem ähnlichen Verlauf der Außentemperatur zu identifizieren, um vergleichbare Betriebsmodi analysieren zu können und die Veränderungen im Systemverhalten (primäre Rücklauftemperatur bzw. Leistungsaufnahme) qualitativ und quantitativ bewerten zu können.

Zeitraum	Datum	Tagesmittel Außentemperatur / ΔT im Tagesmittel	Maximales ΔT im Tagesverlauf
Zeitraum 1 (Referenz)	15.12.2024 (Sonntag)	5,5°C / -	-
Zeitraum 2 (Frühjahr, optimiert)	30.03.2025 (Sonntag)	5,6°C / ΔT 0,1 K	3,5 K
Zeitraum 3 (Winter, optimiert)	28.11.2025 (Freitag)	5,3°C / ΔT 0,2 K	3,5 K

Tabelle 2: Kriterien der ausgewählten Vergleichstage

2. Gesamtheitliche Analyse über die vollständigen Zeiträume

Ergänzend zum exemplarischen Tagesvergleich wurde eine statistische Analyse über die gesamten Messzeiträume durchgeführt, um die Robustheit der Ergebnisse über verschiedene Witterungsbedingungen hinweg zu überprüfen. Hierzu wurden für alle verfügbaren Tage Tagesmittelwerte der Außentemperatur sowie der primären Rücklauftemperaturen berechnet.

Die Analyse erfolgte mittels Streudiagrammen (Außentemperatur vs. Rücklauftemperatur) mit robusten Regressionsgeraden (Huber-Regression), die unempfindlich gegenüber Ausreißern ist. Dabei wurden folgende Vergleiche durchgeführt:

- Zeitraum 1 (Referenz, nicht optimiert): Separate Regressionsgerade für den Referenzzeitraum
- Zeiträume 2 und 3 (optimiert, kombiniert): Gemeinsame Regressionsgerade für beide optimierten Zeiträume (Frühjahr und Winter)

Durch den Vergleich der Regressionsgeraden lässt sich die durchschnittliche Absenkung der Rücklauftemperatur über den gesamten Außentemperaturbereich quantifizieren. Die Kombination von Zeitraum 2 und 3 in einer gemeinsamen Regression ermöglicht dabei eine robustere Bewertung der Optimierungseffekte unabhängig von saisonalen Einflüssen.

Im Folgenden werden die Ergebnisse aus beiden Analysemethoden dargestellt und diskutiert. Ziel ist es, die Auswirkungen der Regleroptimierung sowohl auf Tagesvergleich als auch im Durchschnitt sichtbar zu machen und die Wirksamkeit umfassend zu bewerten.

Exemplarischer Tagesvergleich (Analysemethode 1):

Zur Bewertung der Effekte der durchgeführten Optimierung wurden für die definierten Vergleichstage folgende Auswertungen durchgeführt:

- Tagesverlaufsdiagramme: Visualisierung des zeitlichen Verlaufs von: Außentemperatur, Primärseitiger Vorlauf- und Rücklauftemperatur, übertragene Wärmeleistung
- Histogramme der Rücklauftemperaturen: Analyse der Verteilung der Rücklauftemperaturen über den Tagesverlauf zur Bewertung typischer Temperaturniveaus
- Kumulierte Wärmemenge je Tag: Gegenüberstellung der täglich zugeführten Wärmemenge für die Raumheizung zur möglichen Beurteilung von Energieeinsparungen durch Reduktion des Spielraums bei der Heizungsnutzung und bei vergleichbarer Witterung.

Im Folgenden werden die Vergleichstage anhand der beschriebenen Diagrammtypen dargestellt und analysiert. Ziel ist es, die Auswirkungen der Maßnahmen auf Rücklauftemperaturen, Wärmeleistung und Energieverbrauch unter vergleichbaren Witterungsbedingungen sichtbar zu machen.

Aufgrund der sehr eingeschränkten Datenlage stellen die in diesem Kapitel gezogenen Schlussfolgerungen aus den Analysen und Vergleichen zwischen den gewählten Vergleichstagen nur eine erste Indikation für die Wirkung der Optimierung dar. Da es sich ausschließlich um Einzelfallbetrachtungen handelt, ist für eine statistisch valide Aussage ein längerfristiger Vergleich erforderlich. Die im Folgenden genannten Werte haben somit aufgrund der eingeschränkten Datenlage für den Vergleich nur eine sehr bedingte Aussagekraft, die Ergebnisse lassen sich so nicht ohne Weiteres ursächlich auf die durchgeführte Optimierung an der HAST zurückführen.

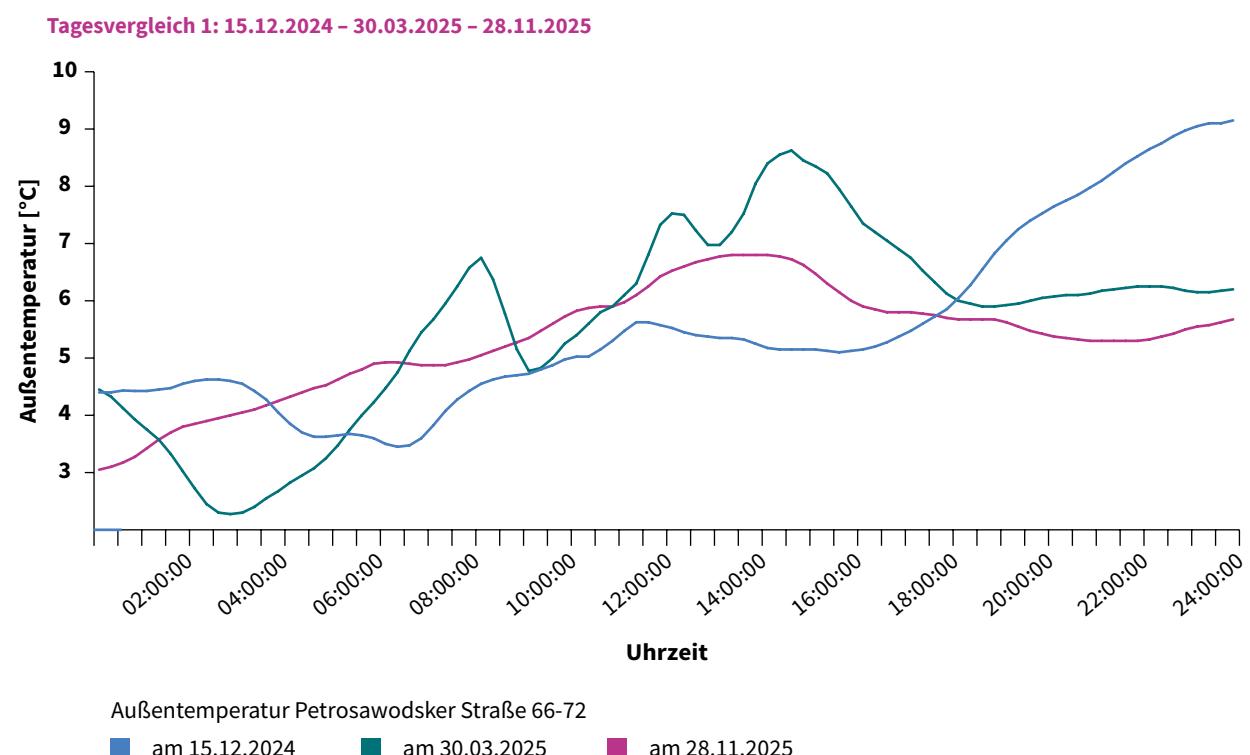


Abbildung 10: Außenlufttemperaturen, 15.12.2024, 30.03.2025 und 28.11.2025

Die Außentemperaturen für die Vergleichstage 15.12.2024, 30.03.2025 und 28.11.2025 sind ähnlich (siehe Tabelle 2), wie in der Abbildung oben jedoch zu sehen, schwankt die Außentemperatur an diesem Tag im März mehr als im Dezember oder November.



Abbildung 11: Außenlufttemperaturen 15.12.2024, 30.03.2025 und 28.11.2025 und der zwei vorherigen Tage

Ähnlich wie in Abbildung 10 zeigt auch Abbildung 11 eine größere Schwankung der Außentemperaturen im März im Vergleich zum Dezember oder November. Auch sind die Tage vor den

gewählten Vergleichstagen im März deutlich wärmer, was vor allem im Hinblick auf die abgenommene Wärmemenge bei der Interpretation der Ergebnisse zu berücksichtigen ist.

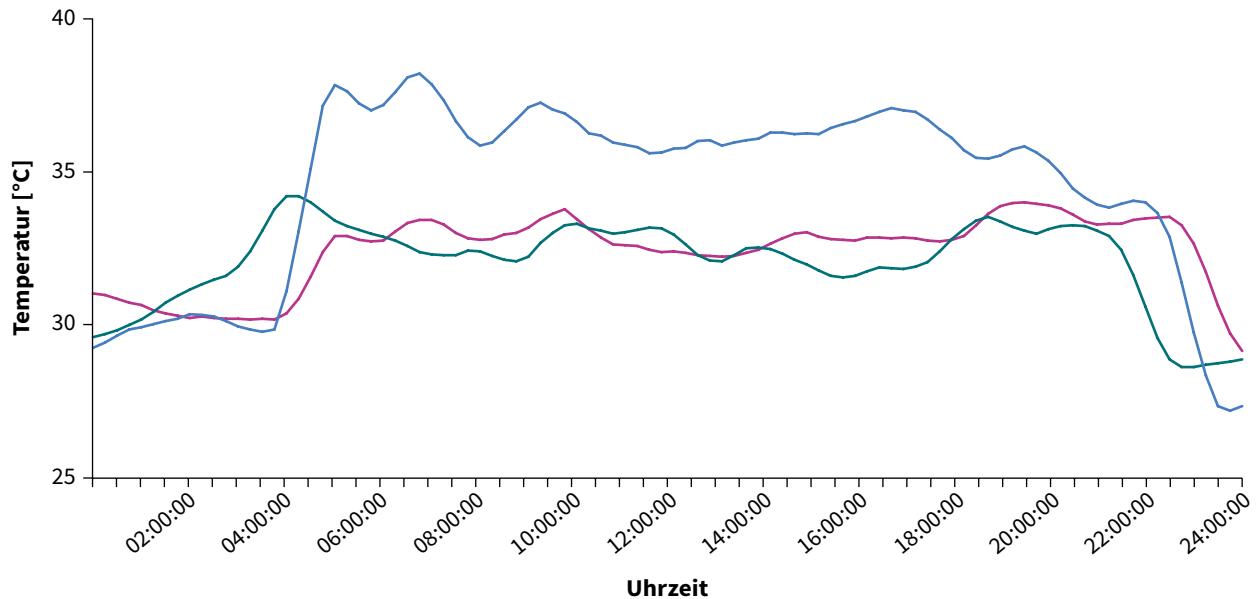


Abbildung 12: Primäre Rücklauftemperaturen Petrosawodsker Straße 66-72 15.12.2024, 30.03.2025 und 28.11.2025

Die obige Abbildung zeigt die primärseitigen Rücklauftemperaturen für die gewählten Vergleichstage von der Liegenschaft Petrosawodsker Straße 66-72 (mit optimierten Reglerparametern im März und November), als auch die Rücklauftemperaturen mit den ursprünglichen Reglerparametern (Dezember). An

den Verläufen lässt sich erkennen, dass es zu einer Rücklauftemperaturabsenkung in der Petrosawodsker Straße 66-72 nach der Optimierung der Parameter kam. Dies wird im folgenden Histogramm noch einmal deutlicher dargestellt.

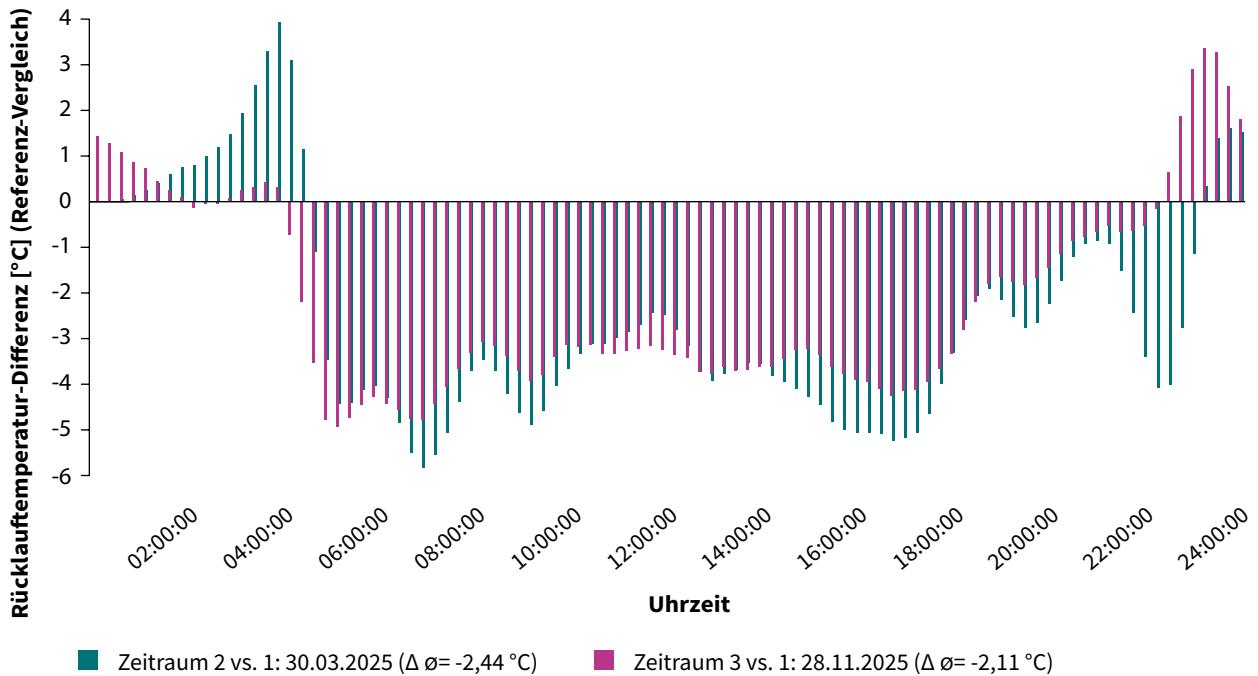


Abbildung 13: Histogramm der Rücklauftemperaturabsenkung (primär) Petrosawodsker Straße 66-72 15.12.2024 im Vergleich zu 30.03.2025 und 28.11.2025

Das Histogramm zeigt eine Absenkung der Rücklauftemperaturen für die Liegenschaft Petrosawodsker Straße 66-72 für die Vergleichstage. Für diesen Fall bedeutet dies, dass die

Optimierung der Reglerparameter einen positiven Einfluss auf die Rücklauftemperatur hat.

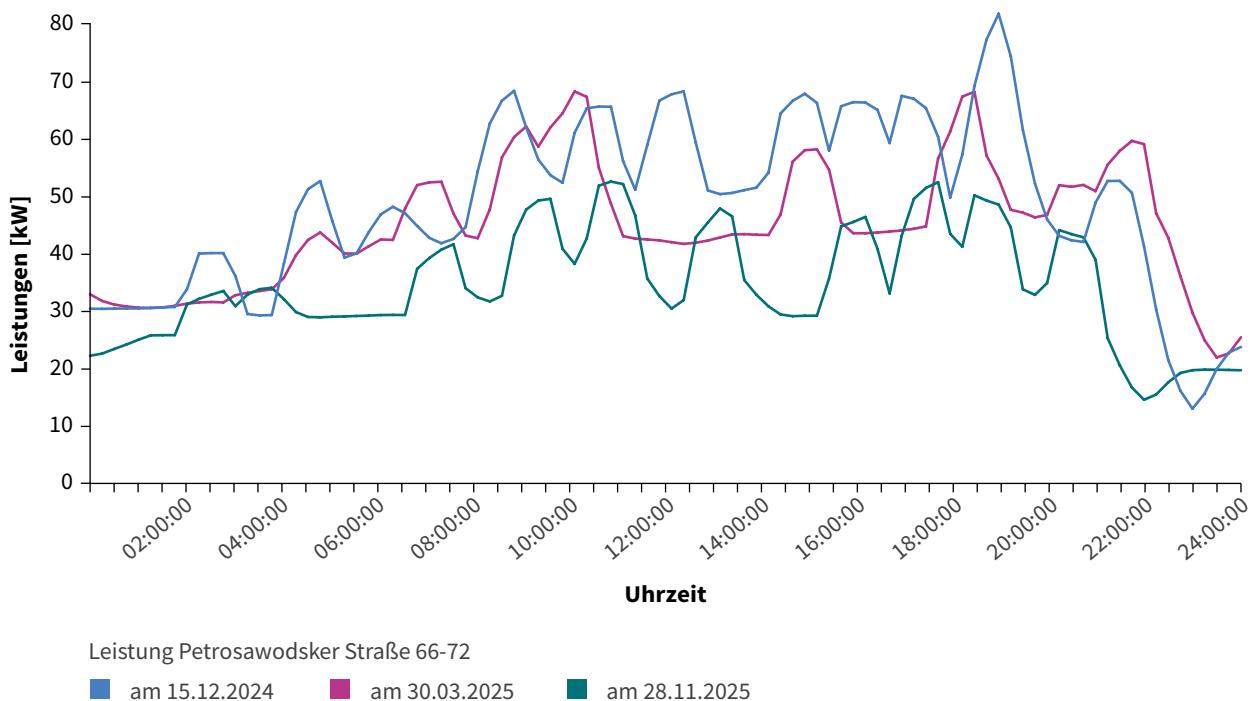


Abbildung 14: Leistungsabnahme im Tagesverlauf Petrosawodsker Straße 66-72, 30.03.2025 und 28.11.2025

Die obige Abbildung zeigt den zeitlichen Verlauf der Wärmeleistungsaufnahme der Liegenschaft Petrosawodsker Straße 66-72 für die Vergleichstage. Ob die Unterschiede in den Kurven auf

die Optimierungsmaßnahmen der HAST zurückzuführen sind, lässt sich anhand der Datenlage nicht vollständig belegen.

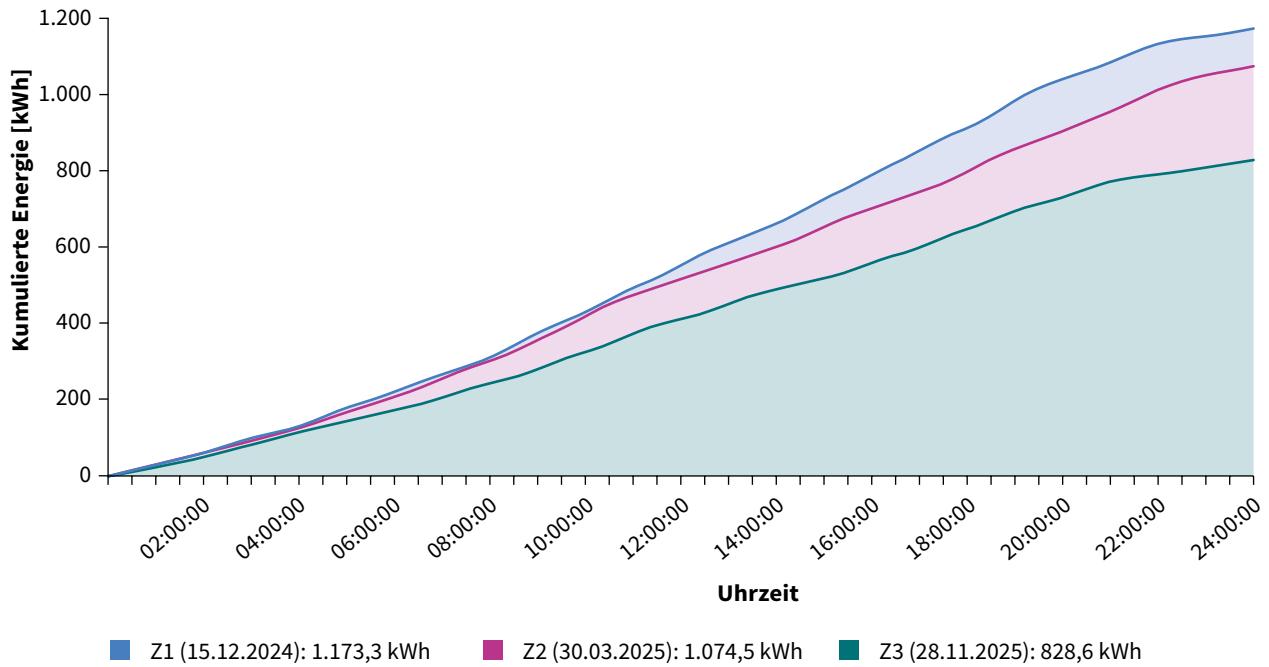


Abbildung 15: kumulierte Wärmemenge Petrosawodsker Straße 66-72, 15.12.2024, 30.03.2025 und 28.11.2025

Die obige Abbildung zeigt die kumulierten Wärmemengen der Liegenschaft Petrosawodsker Straße 66-72 für die Vergleichstage. Wie zu erkennen, ist die übertragene Wärmemenge am 30.03.2025 mit 830 kWh und am 28.11.2025 mit 1075 kWh geringer als am 15.12.2024, wo 1173 kWh übertragen wurden. Die an den Vergleichstagen ähnlichen Umgebungstemperaturen sollten dazu führen, dass die benötigte Wärmemenge zum Heizen des Gebäudes nahezu identisch ist, unabhängig von der Optimierung der HAST. Die Unterschiedlichen Wärmemengen deuten deshalb eher darauf hin, dass sich das Nutzerverhalten verändert hat (weniger Warmwasserbedarf, niedrigere Einstellung der Heizkörper, etc.) oder durch die Optimierung verändert wurde (Decklung der max. Heizleistung vermeidet ggf. unabsichtliche Überheizung der Räume). Rein rechnerisch kann eine Minderverbrauch von 343 kWh oder 29 %, beziehungsweise 98 kWh oder 8,4 % dargestellt werden (siehe Tabelle 3). Diese Werte haben jedoch auf Grund der geringen Datenlage nur eine bedingte Aussagekraft (siehe oben). Die Situationen im Dezember und März, beziehungsweise November, weichen schon bei den Außentemperaturverläufen ab, Aussagen zu weiteren

wichtigen Werten, wie der Solarstrahlung, Gebäudenutzung etc. können wegen der fehlenden Daten nicht getroffen werden. Damit kann nur von einer Indikation, die auf mögliche Energieeinsparungen von ungefähr 8-9 % hinweist, gesprochen werden, deren Ursachen allerdings nicht aus den zur Verfügung stehenden Daten spezifiziert werden können. Um gesicherte Aussagen zu einer möglichen Energieeinsparung durch die Optimierung der Reglerparameter zu treffen, ist eine bessere Datenbasis durch längerfristige Messungen nötig.

Datum	Rechnerischer Gesamtverbrauch am Tag [kWh]
15.12.2024 (Sonntag)	1.173
30.03.2025 (Sonntag)	830
28.11.2025 (Freitag)	1.075

Tabelle 3: Rechnerische Energieeinsparung Petrosawodsker Straße 66-72, für die spezifischen Situationen an den Tagen 15.12.2024 gegenüber 30.03.2025 und 28.11.2025

Gesamtheitliche Analyse:

Zur Bewertung der Effekte der durchgeführten Optimierung wurden folgende Auswertungen durchgeführt.

- Statistische Kennwerte: Ermittlung von Steigung und Achsenabschnitt der Regressionsgeraden zur Charakterisierung des temperaturabhängigen Verhaltens
- Streudiagramm der anderen Liegenschaften zum Vergleich

- Streudiagramm mit Regressionsgeraden: Darstellung der Tagesmittelwerte (Außentemperatur vs. Rücklauftemperatur) mit robusten Huber-Regressionsgeraden der optimierten Liegenschaft Petrosawodsker Straße 66-72 anhand der Zeiträume 1-3

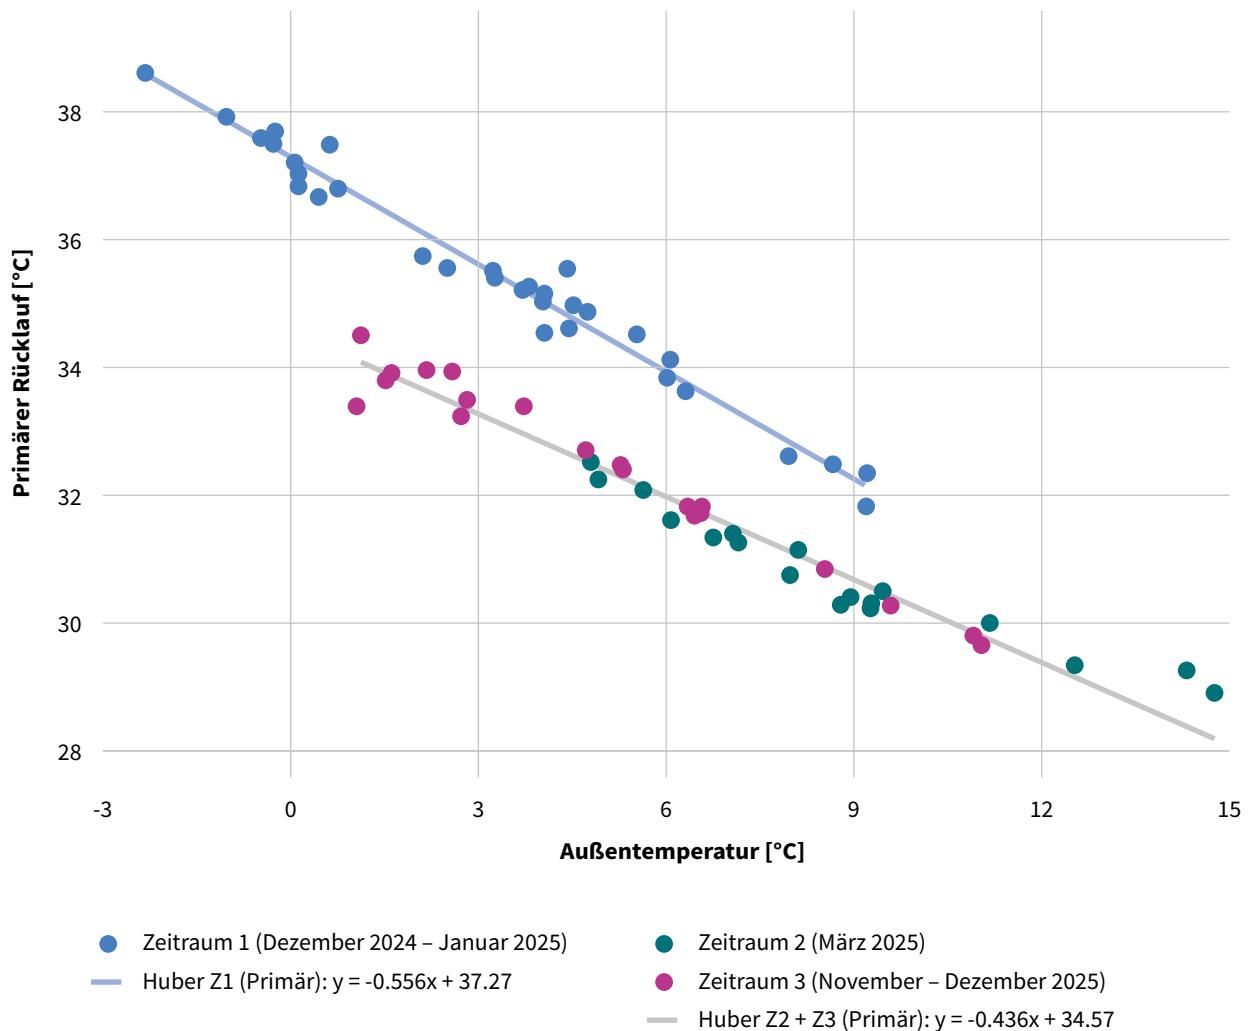


Abbildung 16: Streudiagramm der Tagesmittelwerte der Außentemperatur (x-Achse) und der primären Rücklauftemperatur (y-Achse) der Zeiträume 1-3 der Petrosawodsker Straße 66-72 inkl. Regressionsgeraden

Die Regressionsgerade im Streudiagramm der Liegenschaft Petrosawodsker Straße 66-72 für den Zeitraum 1 vor Optimierung und diejenige für die Zeiträume 2-3 nach der Optimierung zeigen eine fast parallele Verschiebung der Rücklauftemperaturen in Abhängigkeit der Außenlufttemperatur um etwa - 2 K (bei mittlerer Außentemperatur von 5°C beträgt ΔT -2,1 K).

Die ähnliche Steigung beider Geraden (Zeitraum 1: $m = -0,56x$, Zeitraum 2-3: $m = -0,44x$) zeigt, dass die Temperaturabhängigkeit des Systems unverändert bleibt. Die Optimierung hat das

hydraulische Verhalten nicht beeinträchtigt, sondern lediglich das Temperaturniveau systematisch abgesenkt.

Die nahezu parallele Verschiebung bedeutet, dass die Rücklauftemperaturabsenkung über den gesamten Temperaturbereich nahezu konstant ist. Dies zeigt die wetterunabhängige Wirkung der Regleroptimierung.

Die Kombination der Zeiträume 2 und 3 zeigt eine konsistente Datenlage ohne saisonale Abweichungen.

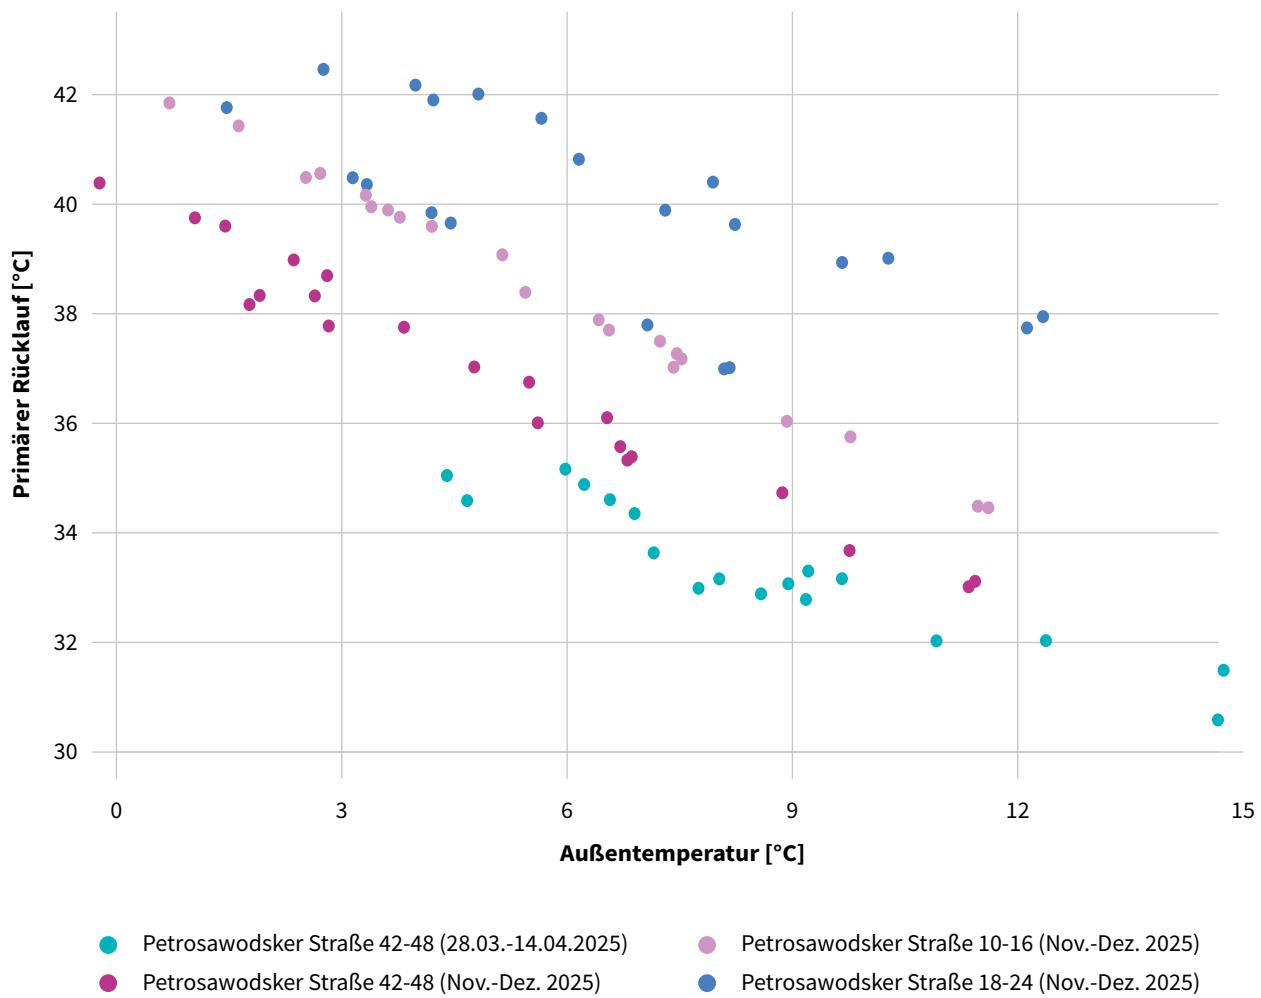


Abbildung 17: Streudiagramm der Tagesmittelwerte der Außentemperatur (x-Achse) und der primären Rücklauftemperatur (y-Achse) der Petrosawodsker Straße 42-48 (Frühjahr und Winter), Petrosawodsker Straße 10-16 (Winter), Petrosawodsker Straße 18-24 (Winter)

Das Streudiagramm in Abbildung 17 zeigt die Tagesmittelwerte der Außentemperatur und der primären Rücklauftemperatur der Vergleichsliegenschaften Petrosawodsker Straße 10-16, 18-24 und 42-48. Es ist ein grundsätzlich höheres Temperaturniveau im Vergleich zur optimierten Liegenschaft erkennbar. Dieses Niveau ist mindestens um 3 K erhöht.

Analyse der Rücklauftemperaturen der Vergleichszeiträume

► Die Auswertung der Tagesverläufe der Rücklauftemperaturen zeigt deutliche Unterschiede zwischen der Liegenschaft mit optimierten Reglerparametern und mit nicht optimierten Reglerparametern. Bei der Liegenschaft mit optimierten Reglerparametern ist insbesondere tagsüber eine signifikante Absenkung der Rücklauftemperatur erkennbar. Dies weist auf eine erfolgreiche hydraulische und regelungstechnische Optimierung hin und kann somit als Proof-of-Concept des hier getesteten Verfahrens gewertet werden.

Ergebnisse der Datenanalyse

- Reduzierung der Rücklauftemperatur: Die Rücklauftemperatur konnte im betrachteten Gebäude (Petrosawodsker Straße 66-72) um min. 2 K gesenkt werden – im direkten Vergleich zur Referenz (Petrosawodsker Straße 42-48) sogar um 3 K. Dies deutet auf eine verbesserte Wärmeabnahme und eine effizientere Systemnutzung hin.
- Energieeinsparung: Der Wärmebedarf an den Vergleichstagen ist rein rechnerisch um rund 29 %, beziehungsweise 8,4 % reduziert. Eine Rückführung dieses Effektes kann nur sehr bedingt oder teilweise auf die optimierten Reglereinstellungen zurückgeführt werden und kann nur mit einer breiteren Datenbasis quantifiziert und belegt werden. Eine Absenkung des Wärmebedarfs von 8-9 % kann jedoch als realistisch eingeschätzt werden. Diese Reduktion würde sich auf die Heizkosten auswirken (vergleiche Tabelle 7 im Anhang). Doch auf Grund der geringen Datenlage kann an dieser Stelle nur von einer Indikation gesprochen werden. Um Aussagen zu

einer Energieeinsparung durch die Optimierung der Reglerparameter treffen zu können, ist eine breitere Datenbasis nötig.

- Leistungsvergleich zwischen den Vergleichsgebäuden nicht möglich: Ein direkter Vergleich der benötigten Heizleistung mit dem zweiten Gebäude war nicht möglich, da die Daten nicht vorhanden sind.

Die ausgewählten Vergleichstage sind in ihrer Witterung / der Außenlufttemperatur grundsätzlich vergleichbar. Es zeigt sich jedoch, dass die Frühlingstage stärkere tageszeitliche Schwankungen der Außentemperatur als die Tage im Winter aufweisen. Zudem unterscheiden sich die Tage unmittelbar vor den gewählten Vergleichstagen im Frühling geringfügig von denen im Winter, was Einfluss auf das thermische Verhalten des Gebäudes haben kann (Wärmespeicherfähigkeit der Baukonstruktion). Eine umfassendere Bewertung war auf Grund der begrenzten Datenverfügbarkeit nicht möglich. Für eine robuste Bewertung ist es nötig, in einer weiteren Winterperiode zusätzliche Vergleichsdaten zu erheben.

Zudem war eine vollständige Bewertung der Versorgungssicherheit nicht möglich, da keine Innenraumtemperaturen gemessen wurden. Es liegen keine objektiven Daten darüber vor, ob die gewünschten Raumtemperaturen in allen Wohnungen erreicht wurden. Allerdings wurden in der ersten Testperiode (Frühjahr 2025) keine Beschwerden von Nutzerinnen und Nutzer gemeldet, in der zweiten Testperiode (Herbst 2025) kam es jedoch zu direkten Anmerkungen zur Heizleistung. Die Unterschiede im Wärmeverbrauch deuten dennoch darauf hin, dass sich das Heizverhalten der Nutzerinnen und Nutzer verändert haben könnte. Sollte dies nicht aktiv durch die Nutzenden beabsichtigt, sondern auf die optimierten Einstellungen an der HAST zurückzuführen sein, wäre dies ein Indiz dafür, dass die Optimierungen den Nutzerinnen und Nutzern helfen, unbeabsichtigt hohe Raumtemperaturen zu vermeiden. Es wurde ergänzend eine Nutzerbefragung durchgeführt, deren Ergebnisse im Folgenden dargestellt werden.

Ergebnisse der Nutzerbefragung

Zur Bewertung der Versorgungssicherheit und Nutzerzufriedenheit wurde ergänzend eine Nutzerbefragung für den Zeitraum von Dezember 2024 bis April 2025 mittels Fragebogen durchgeführt. Ziel war es, subjektive Rückmeldungen zur Raumtemperatur und zum Komfort während des Testzeitraums systematisch zu erfassen.

Die standardisierte Befragung diente dazu, subjektive Einschätzungen der Bewohnerinnen und Bewohner zu erfassen, um diese mit vorhandenen Verbrauchsdaten in Beziehung setzen zu können. Sie ergänzt somit die messtechnischen Erhebungen im Projekt durch eine nutzerzentrierte Perspektive.

Abgefragt wurden unter anderem:

- Haushaltsstruktur und typische Anwesenheitszeiten
- Subjektives Temperaturempfinden in verschiedenen Räumen (Wohn-, Schlaf-, Bade- und Arbeitszimmer) sowie an Kopf und Füßen
- Thermostateinstellungen in verschiedenen Nutzungssituationen (tagsüber, nachts, bei Abwesenheit)
- Lüftungsverhalten (Dauer, Häufigkeit und Gründe)
- Zufriedenheit mit der Heizungsregelung

Diese Erhebung stellt eine erste qualitative Annäherung an das Komfortempfinden der Nutzenden dar. Leider gab es im Rahmen der Untersuchungen nur zwei Antworten von Nutzerinnen und Nutzern, was die Aussagekraft der Befragung stark limitiert.

Für die Auswertung stehen nur zwei ausgefüllte Fragebögen von jeweils einer Wohnung mit den Antworten der Nutzerinnen und Nutzer zur Verfügung.

Beide Wohnungen wurden durchgehend von zwei anwesenden Erwachsenen bewohnt. In beiden Fällen wurde das Raumklima sehr konstant und positiv bewertet, mit Temperaturwahrnehmung „genau richtig“ über den gesamten Erhebungszeitraum. Unterschiede zeigten sich in der Nutzung der Thermostatköpfe:

- Wohnung 1 passte im Frühjahr die Heizstufen leicht nach unten im Wohnzimmer und Arbeitszimmer an. Die anderen Räume sind unbeheizt (Thermostatkopf auf 0).
- Wohnung 2 ließ die Einstellungen unverändert und nutzte generell nur das Wohnzimmer als beheizten Raum (Stufe 2), alle anderen Räume blieben unbeheizt.

Auch beim Lüftungsverhalten war ein Unterschied sichtbar:

- Wohnung 1 lüftete im Frühjahr länger (30–60 Minuten), in der Heizperiode kürzer. Gelüftet wurde aufgrund verbrauchter Luft.
- Wohnung 2 zeigte durchgehend gleichmäßige Lüftungszeiten (10–30 Minuten).

Beide Haushalte gaben an, nicht länger als zwei Tage abwesend gewesen zu sein, was die Validität der Angaben zur Nutzung und Temperaturwahrnehmung stützt.

Fazit der Nutzerbefragung

Die stichprobenartige Nutzerbefragung in zwei dauerhaft bewohnten Wohnungen zeigt eine Indikation, dass die Bewohner mit der Heizungsregelung insgesamt zufrieden waren. In beiden Haushalten wurde das thermische Komfortempfinden durchgängig als „genau richtig“ beschrieben, sowohl in der Hauptheizperiode (Dezember bis Februar) als auch im Übergangszeitraum (März bis April). Zu kühle Temperaturen wurden nicht angegeben.

Die Ergebnisse der Nutzerbefragung im Frühling 2025 relativieren sich durch Rückmeldungen einiger weniger NutzerInnen während der Testperiode Herbst 2025. Nach der Wiederaufnahme des Heizbetriebes im Herbst 2025 gab es einige wenige Rückmeldungen, dass es an sehr kühlen Tagen nicht ausreichend warm werden würde. Eine Analyse ergab, dass eine genauere Analyse der Hydraulik im Gebäude notwendig ist, um das Problem näher zu identifizieren. Alternativ kann eine etwas erhöhte Heizkurve eingestellt werden (Steigung auf 0,7). Mit diesem Sicherheitsaufschlag wird der Effekt der nicht optimierten Hydraulik im Gebäude ausgeglichen.

Somit gibt es zusammenfassend eine Indikation, dass das Gebäude – auch nach der Anpassung der Heizkurve – ausreichend mit Wärme versorgt wurde, um den Bedarf der Nutzer zu decken. Trotz der tendenziell höheren Außentemperaturen im Frühjahr und des damit verbundenen geringeren Heizbedarfs stimmten die subjektiv empfundenen Raumtemperaturen weiterhin mit den Nutzerbedürfnissen überein.

Die Rückmeldungen geben somit eine gewisse positive Indikation, dass die vorgenommenen Optimierungen am Heizsystem – insbesondere die Anpassung der Heizkurve – wirksam und weitgehend bedarfsgerecht waren.

- ▶ Im Testzeitraum 28.03. bis 14.04.2025, sowie 25.11. bis 14.12.2025 sank die primärseitige Rücklauftemperatur um min 2 K; im direkten Vergleich mit einem baugleichen Referenzgebäude waren es sogar rund 3 K. Erste Abschätzungen deuten auf ein mögliches Wärmeeinsparpotenzial von 8-9 % hin. Trotz der Anpassungen blieb der thermische Komfort laut einer kleinen Nutzerbefragung unverändert. Damit ist der „Proof of Concept“ für ML-optimierte Reglerparameter erbracht.

2.6 Potenziale zur Optimierung durch den Projektansatz

Im Rahmen des Projekts sollte anhand eines Use Case demonstriert werden, wie sich durch datenbasierte Optimierung der Heizkurve relevante Einsparpotenziale inklusive einer Rücklauftemperaturabsenkung erschließen lassen. Dazu wurde auf Basis realer Betriebsdaten zunächst ein physikalisches Simulationsmodell erstellt. Dieses diente als Grundlage zur Generierung von Trainingsdaten für ein Surrogate-Modell, das mithilfe eines neuronalen Netzes entwickelt wurde. Dieses Surrogate-Modell bildete das Verhalten des Systems ausreichend genau ab und konnte in einem nachfolgenden Optimierungsschritt zur Identifikation geeigneter Reglerparameter verwendet werden.

Besonders hervorzuheben ist dabei:

- Der Trainingsdatensatz umfasste nur wenige Wochen aus einer Winterperiode, was zeigt, dass auch mit begrenzten Daten aussagekräftige Optimierungen möglich sind.
- Die Anwendung des Surrogate-Modells ermöglichte eine effiziente Optimierung, ohne dass erneut umfangreiche physikalische Simulationen notwendig waren.

Die anschließende Analyse der implementierten Regelung im realen Betrieb zeigte

- eine Reduktion der Rücklauftemperatur von 2 bis 3 K
- eine potenzielle Senkung der kumulierten Wärmemenge über die Vergleichstage von ungefähr 8-9 %
- eine Indikation für eine mögliche Einsparung von Heizkosten gegenüber dem ursprünglichen Zustand

Die Potenziale des Ansatzes liegen insbesondere in

- der verbesserten Regelbarkeit in Übergangszeiten (Frühjahr/Herbst)
- der Erkenntnis, dass eine identische Außentemperatur im Frühjahr andere Auswirkungen hat als im Winter – eine dynamisch angepasste Heizkurve könnte hier zusätzliche Effizienzgewinne ermöglichen
- der Möglichkeit, den Ansatz auf andere Gebäude mit ähnlicher Datenlage zu übertragen
- der Tatsache, dass keine umfassende Sensorik (z. B. Innenraumtemperaturmessung) notwendig war

Der hier vorgestellte Use Case zeigt exemplarisch das Potenzial der datenbasierten Optimierung auf Gebäudeebene. Um dieses Potenzial systematisch zu heben, ist es notwendig, solche Ansätze auf weitere Liegenschaften zu übertragen.

Herausforderungen bei der Übertragbarkeit

Die für die Skalierung der Methode notwendige Standardisierung des Modells ist aufgrund individueller Gegebenheiten (Gebäudetechnik, Nutzerverhalten, hydraulische Einbindung) anspruchsvoll. Eine direkte Übertragung der Methodik ist daher nicht ohne Weiteres möglich. Es besteht weiterer Forschungsbedarf, um

- übertragbare Modellierungsansätze für typische Gebäudekonfigurationen zu entwickeln
- ML-Ops Pipelines zur automatisierten Kalibrierung und Validierung zu nutzen
- rein datenbasierte Modelle zur dynamischen Betriebsoptimierung zu erproben

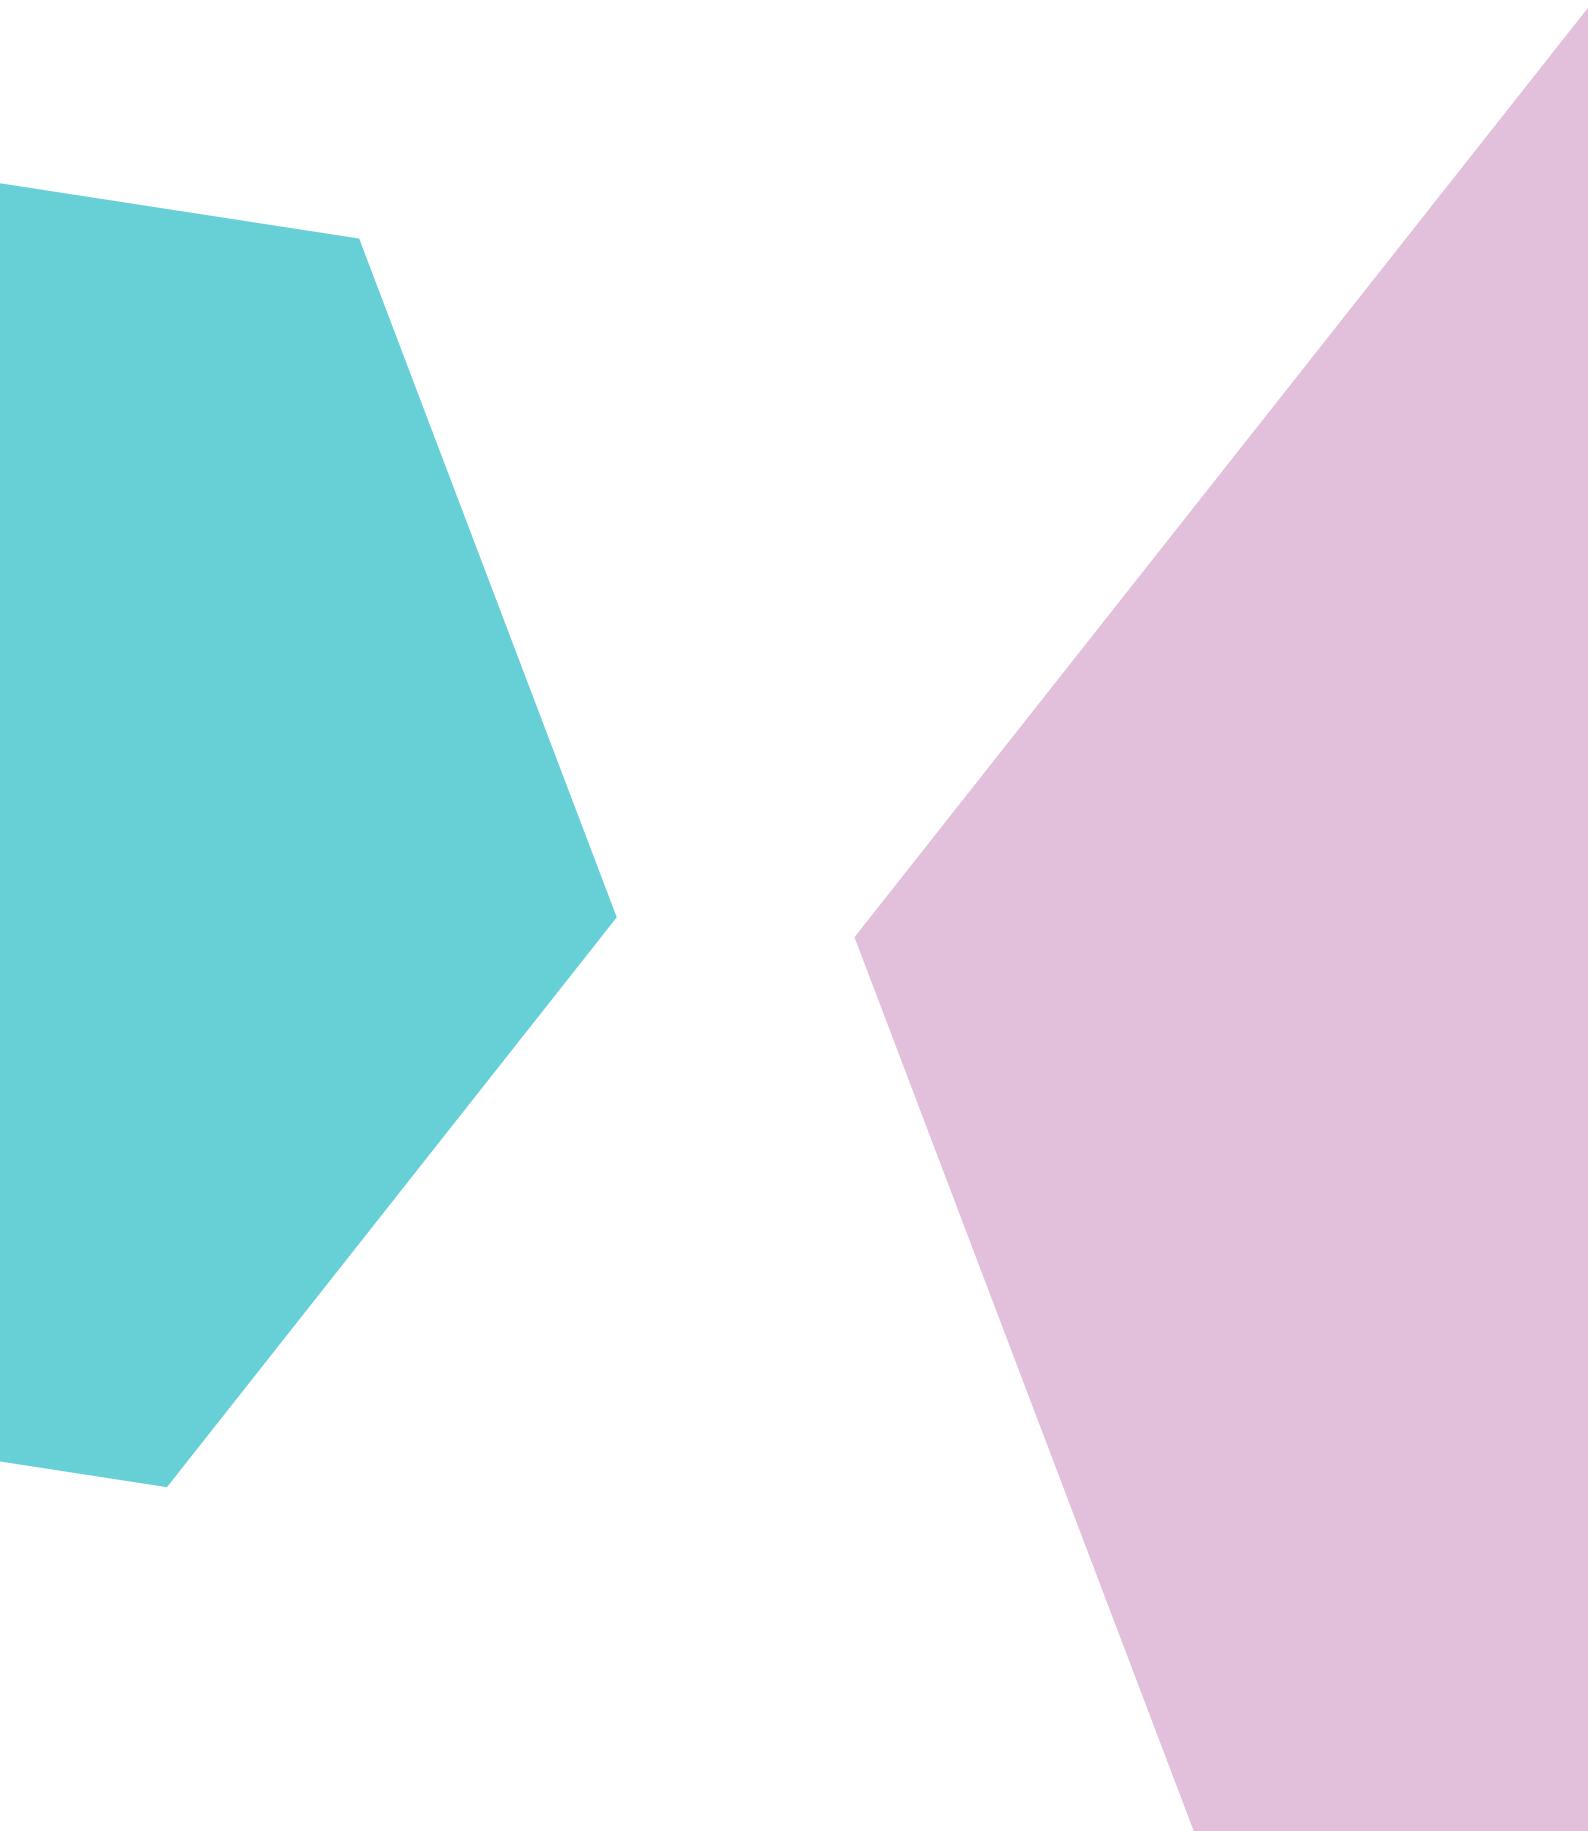
2.7 Fazit der Umsetzung des Use Case

Der im Projekt verfolgte Ansatz zeigt exemplarisch, wie mithilfe von Methoden des maschinellen Lernens Verbesserungen im Fernwärmesystem möglich sind. Der ausgeführte Use Case des Auto- und Continuous-Commissioning von Regelgeräten

an realen Fernwärme-Hausstationen zeigt dies. Unter Auto-Commissioning wird eine automatisierte Anpassung von Reglerparametern an die individuellen Betriebsbedingungen des jeweiligen Gebäudes verstanden. Dies soll sicherstellen, dass eine optimale Regelung der Hausstationen erreicht wird. Beim Continuous-Commissioning wird zudem eine kontinuierliche Anpassung der Reglerparameter an sich verändernde Betriebsbedingungen betrachtet.

Der Projektansatz belegt ein klares Optimierungspotenzial für die Bereitstellung von optimierten Reglerparametern. Wie ausgeführt, kann eine Reduktion der Rücklauftemperaturen von HAST in der Größenordnung von 2 bis 3 K durch diese Maßnahmen erreicht werden, was zu einer Effizienzsteigerung des Fernwärmesystembetrags und zu einer Kostenreduktion für den FernwärmeverSORGUNGSUNTERNEHMEN führt. Mit einem Cost Reduction Gradient (CRG) von ca. 0,5 bis 0,65 €/MWh*K bei der Wärmeerzeugung beispielsweise mit Wärmepumpen (siehe Averfalk et al. 2021) lässt sich eine Kostenreduktion für konkrete Wärmenetze abschätzen. Dies würde bei einer Umsetzung der beschriebenen Methode auf alle Gebäude im Fernwärmennetz in Neubrandenburg mit einer jährlichen Wärmeabgabe von ca. 237 GWh eine Einsparung von ungefähr 355.000 €/a bedeuten. Für die weitere Skalierung des Verfahrens auf weitere Gebäude und Wärmenetze liegt die Herausforderung nun darin, diesen Ansatz über Einzelobjekte hinaus zu verstetigen und ihn in die Praxis übertragbar zu machen. Dynamisch adaptive Heizkurvenregelungen könnten dabei einen zentralen Baustein darstellen, insbesondere in den energetisch sensiblen jahreszeitlichen Übergangszeiten.

3. Projektteil 2: Methodik zur Bewertung von ML Use Cases



Künstliche Intelligenz und maschinelles Lernen werden bereits in vielen unterschiedlichen Bereichen eingesetzt. Im Betrieb von Fernwärmesystemen kommen diese Methoden bisher jedoch nur sporadisch zum Einsatz, obwohl es große Potenziale für die Anwendung von ML-Methoden gibt. Der Umsetzung von ML Use Cases stehen allerdings mehrere Hürden im Weg, denn oft ist unklar, welche Möglichkeiten es gibt, mittels ML Effizienzen im Betrieb zu steigern, welche Voraussetzungen für bestimmte Use Cases erfüllt sein müssen, welche Umsetzungsrisiken bestehen und insbesondere wie sich Nutzen und Aufwand des Use Case am Ende darstellen. Um diese Probleme anzugehen, wurde im Rahmen der wissenschaftlichen Begleitung des Projekts ML4FW eine Bewertungsmethode für ML Use Cases im Fernwärmesystembetrieb entwickelt und unter anderem auch auf den im Projekt umgesetzten Use Case zur ML-gestützten Reglerparamet- roptimierung angewandt. Die folgenden Abschnitte beschreiben den Erstellungsprozess, die Funktionsweise, den Mehrwert und die Anschlussmöglichkeiten dieser Methodik. Das Ziel war dabei, eine möglichst allgemein anwendbare Bewertungsmethode zu entwickeln, die ohne ausgeprägte ML-Expertise angewandt werden kann, um interessante Use Cases zu identifizieren und eine erste Abschätzung von Nutzen, Aufwand und Risiko von ML Use Cases zu erhalten.

3.1 Beschreibung der Methodik

Die im Projekt erarbeitete Bewertungsmethode basiert auf einem zweistufigen Konzept, in dem zunächst eine datenlose, semiquantitative Einschätzung der drei Größen Nutzen, Auf- wand und Risiko ermittelt wird.

Für die erste Phase wurde im Projekt der ML4FW-Fragebogen erstellt, der durch die Abfrage der Präferenzen, Umstände und Voraussetzungen des Anwenders eine personalisierte Auswer- tung von Informationen aus einer hinterlegten Wissensbasis vornimmt. Auf diese Weise kann der Anwender ohne großen Aufwand eine erste Einschätzung zu im Fragebogen hinterlegten Use Cases erhalten und auf Basis einer erstellten Übersicht ent- scheiden, welchen Use Case er tiefergehend evaluieren möchte.

In der zweiten Phase kann der Nutzer dann auf Grundlage seiner Daten eine genauere Auswertung des identifizierten Use Case durch ML-Experten vornehmen lassen, um zu einer finalen Ent- scheidung zu gelangen. Das zweistufige Konzept der Bewertung ist in Abbildung 18 grafisch dargestellt.

Im Rahmen dieses Projekts wurde der ML4FW-Fragebogen zur Durchführung von Phase 1 der Bewertung erarbeitet und in Form einer Python-Anwendung zur allgemeinen Nutzung vorbereitet und in Github veröffentlicht (<https://github.com/AEFDI/ML4FW>). Zudem wurde eine beispielhafte Detailauswertung des Use Case zur Reglerparameteroptimierung (siehe Kapitel 2.5 „Ergebnisse aus dem Feldtest“) vorgenommen. In den nächsten Abschnitten werden der Erstellungsprozess und die Funktionsweise des Frage- bogens beschrieben.

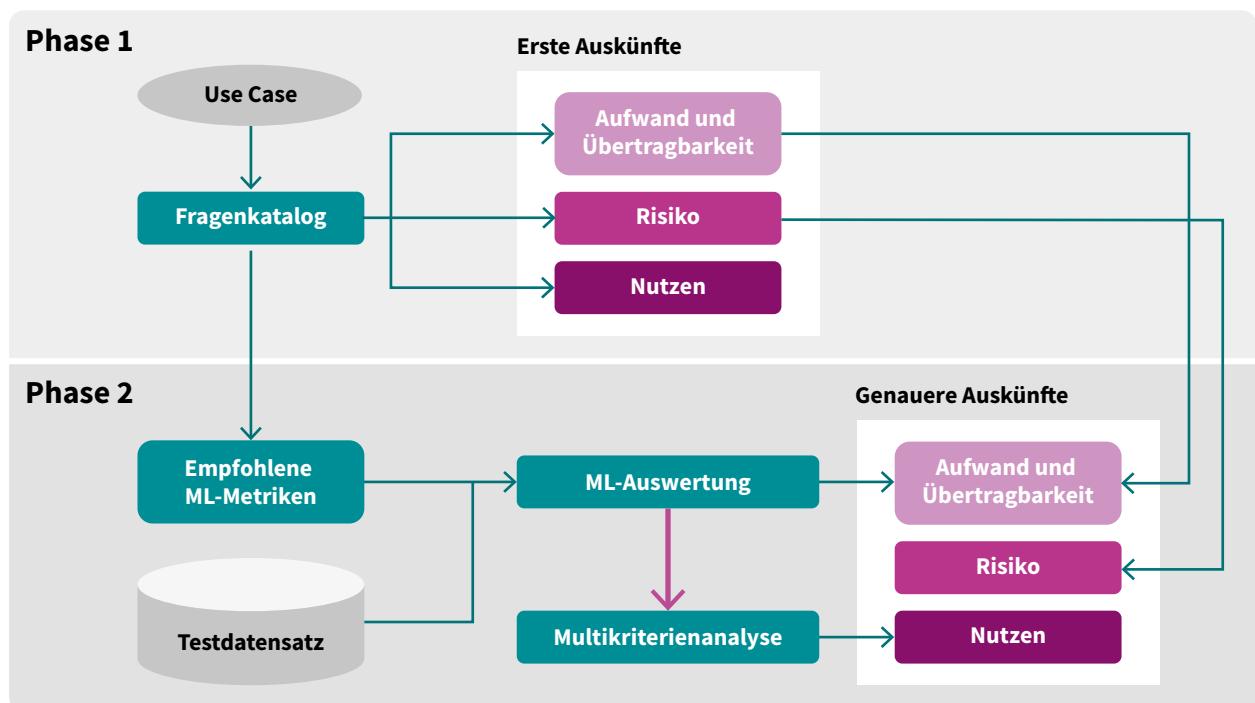


Abbildung 18: Zweistufiges Konzept für die Bewertung von ML Use Cases

Erstellung des Fragebogens

Für die Erstellung des ML4FW-Fragebogens wurden existierende ML Use Cases durch eine Literaturrecherche ermittelt. Analysen von wissenschaftlichen Veröffentlichungen zu diesen Use Cases wurden mit Praxiserfahrungen und Expertenwissen des Fraunhofer IEE, des Fraunhofer IPB, der AGFW und der SAMSON AG zu einer Wissensbasis kombiniert, die die Einschätzung der Use

Cases hinsichtlich verschiedener Kriterien ermöglicht. Auch wurden gewonnene Erfahrungen aus der Erprobung der ML-gestützten Reglerparameteroptimierung berücksichtigt. Durch die Kombination der verschiedenen Informationsquellen wurde ein initiales Bewertungskonzept erstellt, das anschließend iterativ verbessert und in eine Python-Anwendung überführt wurde. Der Erstellungsprozess ist in Abbildung 19 schematisch dargestellt.

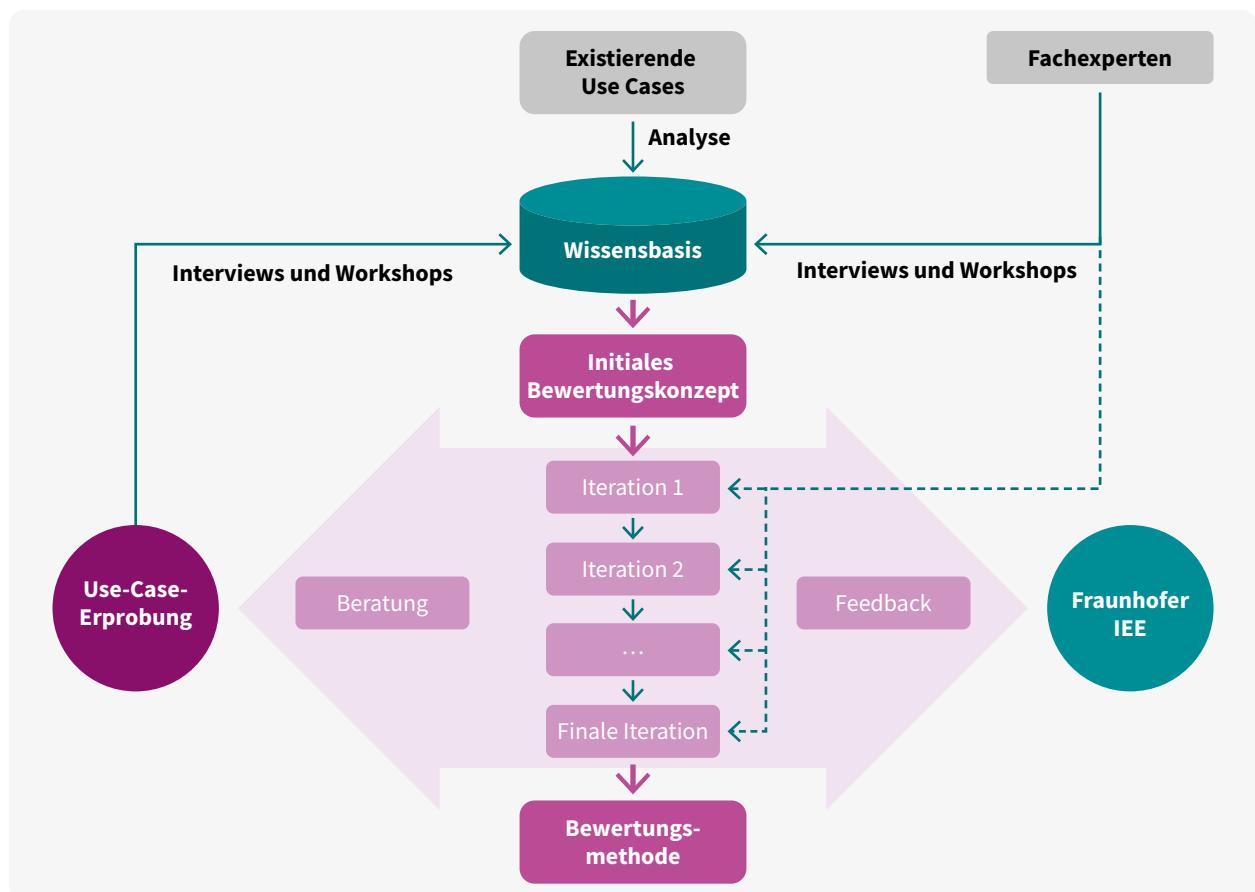


Abbildung 19: Schematische Darstellung des Erstellungsprozesses des Fragebogens zur Bewertungsmethode

Erstellung der Wissensbasis

Für die Erstellung der Wissensbasis wurde zunächst eine Eingrenzung des thematischen Rahmens auf den Fernwärmesystembetrieb vorgenommen. Dies beinhaltet die Verteilung von Wärme durch Rohrnetzwerke sowie den Transfer von Wärme durch Hausstationen und schließt Netzplanungsaspekte sowie die Wärmeproduktion und verbraucherspezifische Use Cases, die sich nicht auf die Hausstation beziehen, aus.

Nach der Eingrenzung des Themas wurden wissenschaftliche Veröffentlichungen zu Use Cases im Bereich des Fernwärmesystembetriebs identifiziert und kategorisiert. Aktuelle Review-Paper zeigen, dass die Vorhersage von Wärmebedarfen mit 72 Prozent den größten Anteil an den existierenden wissenschaftlichen Veröffentlichungen zum Thema ML in der Fernwärme

hat (Mbiydzenyuy 2021). Des Weiteren wurden die Kategorien prädiktive Instandhaltung und Betriebsstrategien identifiziert. Der große Unterschied bei den Anteilen der Kategorien in der Literatur ist unter anderem auf die Umsetzbarkeit und die Datenanforderungen von ML Use Cases aus den jeweiligen Kategorien zurückzuführen. Während Wärmebedarfsprognosen in ihrer einfachsten Form bereits mit verhältnismäßig wenigen, leicht verfügbaren Informationen wie Wetterprognosen und Messungen von Vor- und Rücklauftemperaturwerten realisierbar sind, benötigen Use Cases zum Thema Instandhaltung oftmals detailliertere Informationen über Instandhaltungshistorien und umfangreiche Messdaten. Betriebsstrategien benötigen in der Regel ebenfalls größere Mengen an Daten aus unterschiedlichen Quellen und tendieren zusätzlich zu einer komplexen Umsetzung, da viele Use Cases in diesem Bereich die Koordination

verschiedener Teile des Fernwärmennetzes erforderlich machen. Nicht zuletzt liefern Wärmebedarfsprognosen in einigen Fällen den Grundbaustein, um komplexere Betriebsstrategien umzusetzen.

Für das weitere Vorgehen wurden die Kategorien weiter verfeinert und es wurde eine Unterscheidung zwischen der Instandhaltung des Rohrleitungsnetzes und der Instandhaltung von Hausstationen vorgenommen. Analog wurden die Betriebsstrategien aufgeteilt, sodass sich die Wissensbasis für die Erstellung des Fragebogens zur Bewertung von ML Use Cases im Bereich des Fernwärmesystembetriebs schließlich in fünf Kategorien unterteilen ließ:

- Wärmebedarfsprognosen (WBP)
- Instandhaltung Hausstationen (InHAST)
- Instandhaltung des Rohrleitungsnetzes (InRN)
- Betriebsstrategien Wärmenetz (BeWN)
- Betriebsstrategien Hausstationen (BeHAST)

Aus den ermittelten Kategorien wurden anschließend 19 Use Cases, unter denen sich auch die im Projekt umgesetzte ML-gestützte Reglerparameteroptimierung befindet, für die weitere Berücksichtigung in der Bewertungsmethode ausgewählt. Eine Auflistung der ausgewählten Use Cases inklusive der Literaturquellen und einer kurzen Zusammenfassung ist im Anhang (Tabelle 7) zu finden.

Bewertungskonzept

Für die Bewertung der kategorisierten und ausgewählten ML Use Cases wurde eine gestufte Herangehensweise gewählt. Vergleiche des Nutzens zweier ML Use Cases aus verschiedenen Kategorien stellen sich als besonders herausfordernd dar, weil für die Quantifizierung von Mehrwerten der einzelnen Use Cases unterschiedliche Kriterien relevant sind. Aufgrund dieser Problematik sieht das Bewertungskonzept zunächst eine oberflächliche Abwägung der identifizierten Use-Case-Kategorien gegeneinander vor und legt dafür verallgemeinerte, kategorieübergreifende Kriterien an. Nach der Auswahl der Kategorie werden Use Cases innerhalb der Kategorien bezüglich spezifischer lokaler Kriterien verglichen, die sich von Kategorie zu Kategorie unterscheiden können. Auf diese Weise wird zum einen die Vergleichbarkeit von Use Cases sichergestellt und zum anderen jedes entscheidende Kriterium für die Quantifizierung des Nutzens berücksichtigt. Zudem bietet der Kategorievergleich auf abstrakter Ebene die Möglichkeit, auch die Kategorien an sich zu priorisieren, so dass in einem zweistufigen Verfahren die am besten passenden Use Cases ermittelt werden können. In den nächsten Abschnitten wird die Erstellung der Kategorie- und Use-Case-Vergleiche erläutert.

3.1.1 Einschätzung von ML-Use-Case-Kategorien

Für den Vergleich der ML-Use-Case-Kategorien werden die sieben globalen Bewertungskriterien Kostenaufwand, Zeitaufwand, Personalaufwand, Versorgungssicherheit, Umweltauswirkungen, Automatisierungsgrad und Energieeffizienz angelegt. Sie werden durch die Zuweisung einer Zahl zwischen 1 und 5 quantifiziert. Die Zahl 1 stellt dabei eine geringe Relevanz des Kriteriums dar und 5 drückt dementsprechend eine sehr hohe Relevanz aus.

Die sieben Kriterien werden nach der Auswertung in die Größen „Nutzen“ und „Aufwand“ zusammengefasst. Die Größe „Aufwand“ setzt sich aus den Kriterien Kostenaufwand, Zeitaufwand und Personalaufwand zusammen, wohingegen die Größe „Nutzen“ durch die Kriterien Versorgungssicherheit, Umweltauswirkungen, Automatisierungsgrad und Energieeffizienz bestimmt wird.

Um die passenden Zahlenwerte für jede Kategorie und jedes Kriterium zu ermitteln, wird innerhalb des ML4FW-Fragebogens zunächst die Priorisierung der Kriterien durch den Anwender abgefragt, wobei er jedem Kriterium ein Gewicht zwischen 1 und 5 zuweist. Diese Anwenderpräferenzen werden anschließend mit einer hinterlegten Experteneinschätzung für jede Kategorie und jedes Kriterium verrechnet und durch Mittelwertbildung zu den letztendlichen Nutzen- und Aufwandszahlen zusammengefasst. Die hinterlegte Experteneinschätzung basiert auf einer Umfrage, die im Rahmen des Projekts durchgeführt wurde. In dieser Umfrage wurden neun Experten des Fraunhofer IEE, des Fraunhofer IPB und der AGFW zu ihren Einschätzungen bezüglich der fünf ML-Use-Case-Kategorien und der sieben Kriterien befragt. Die finale Experteneinschätzung wird durch den Mittelwert der Umfragerückmeldungen dargestellt. Genaueres zu den Ergebnissen der Umfrage ist in Abschnitt 3.2.2 „Ergebnisse der Kategorieumfrage“ zu finden.

Neben den Größen „Nutzen“ und „Aufwand“ wird zudem eine Einschätzung des Umsetzungsrisikos für jede Kategorie ermittelt, indem Antworten des Anwenders zu Fragen in Bezug auf Datenzugriffsrechte und mögliche Konflikte bei der Umsetzung des Use Case ausgewertet werden.

3.1.2 Einschätzung der ML Use Cases

Für die Einschätzung der ML Use Cases wurden innerhalb jeder der fünf ML-Use-Case-Kategorien spezifische Kriterien definiert. Beispielsweise setzt sich der Nutzen eines Use Case aus der Kategorie „Instandhaltung Hausstationen“ unter anderem aus Kriterien wie „Fehlerfrüherkennung“ und „Anzahl Fehlalarme“ zusammen, wohingegen der Nutzen eines Use Case aus der Kategorie „Wärmebedarfsprognosen“ Kriterien wie „Genauigkeit der Prognose“ und „Berücksichtigung des Kundenkomforts“ beinhaltet.

Um den Nutzen eines ML Use Case hinsichtlich der angelegten lokalen Kriterien zu quantifizieren, nimmt der Anwender zunächst eine weitere subjektive Gewichtung analog zum Vorgehen bei der Kategorieeinschätzung vor. Anschließend werden diese Gewichtungen mit hinterlegten Experteneinschätzungen des Projektbearbeitungsteams verrechnet.

Für die Einschätzung des Aufwands werden kategoriespezifische Fragen zu Themen wie Datenverfügbarkeit, Datenaufbewahrungs aufwand und Metadatenverfügbarkeit durch den Anwender beantwortet und mit Experteneinschätzungen zu einem finalen Aufwandswert kombiniert.

Zuletzt wird für jeden Use Case ein Umsetzungsrisikowert bestimmt. Das Risiko eines Use Case wird als Mittelwert des zugehörigen Kategorierisikos und einer festgelegten Experteneinschätzung von 1 bis 5 berechnet.

Eine detaillierte Beschreibung der Bewertungsmethode sowie die konkrete Implementation ist im frei zugänglichen Github-Repository (<https://github.com/AEFDI/ML4FW>) zu finden.

3.2 Ergebnisse der wissenschaftlichen Bewertung

Die Ergebnisse der wissenschaftlichen Bewertung sind in den hinterlegten Experteneinschätzungen zu den 19 bewerteten ML Use Cases zusammengefasst. Der für die Personalisierung dieser Einschätzungen konzipierte ML4FW-Fragebogen wurde in eine Python-Anwendung überführt, die für die Use-Case-Einschätzung die folgenden Schritte durchläuft:

1. Kategorieauswahl
2. Gewichtung globaler Kriterien
3. Gewichtung lokaler Kriterien
4. Beantwortung kategorieübergreifender Fragen
5. Kategoriespezifische Fragen zum Risiko
6. Kategoriespezifische Fragen zu Daten und Aufwand
7. Auswertung und Visualisierung der Ergebnisse

Neben der konkreten Umsetzung des Fragebogens als ausführbare Anwendung ist in den nächsten beiden Abschnitten auch die Auswertung der Umfrage zur Erstellung der Kategoriebewertungsgrundlage beschrieben.

3.2.1 Der ML4FW-Fragebogen

Die Bewertungsmethode wurde in Form einer Python-Anwendung umgesetzt, die ein Graphical User Interface (GUI) erzeugt. Dieses ermöglicht es dem Anwender, den Fragebogen zur Einschätzung von ML Use Cases im Bereich Fernwärmesystembetrieb durchzugehen und die gemachten Angaben automatisch ohne Übermittlung von Informationen an einen zentralen Server analysieren zu lassen. Die Python-Anwendung ist in eine unter Microsoft Windows ausführbare EXE-Datei überführt worden und erzeugt nach dem Start das in Abbildung 20 links oben sichtbare Startmenü. In diesem Menü werden der Zweck und der Ablauf des Fragebogens beschrieben. Zudem bietet es die Funktion, einen neuen Fragebogen zu beginnen oder einen existierenden Speicherstand zu laden.

Beim Start eines Fragebogens werden die fünf zur Auswahl stehenden ML-Use-Case-Kategorien angezeigt, wobei der Anwender die für ihn relevanten Kategorien selektieren kann. Anschließend nimmt der Anwender die Gewichtung der globalen Kriterien vor, gefolgt von der Beantwortung der kategoriespezifischen Fragen. Nach dem Abschluss des Fragebogens können die Ergebnisse des Kategorievergleichs grafisch dargestellt werden. Durch Klicken auf die Kategoriepunkte im Graphen können die zur jeweiligen Kategorie gehörenden Use-Case-Vergleiche visualisiert werden (Abbildung 20 rechts oben). Durch das Auswählen eines Use Case öffnet sich dann ein weiteres Fenster, in dem eine kurze Beschreibung, eine zusammenfassende Pro- und Kontra-Tabelle und die Literaturquelle zum jeweiligen Use Case zu finden sind. Darüber hinaus kann sich der Nutzer Handlungsempfehlungen zum ausgewählten Use Case anzeigen lassen. Das Klicken auf den entsprechende Schaltfläche öffnet ein weiteres Fenster in welchem die Vorschläge für die nächsten Schritte – hin zu einer Testumsetzung – gemacht werden (Abbildung 20 untere Reihe). Dabei werden mögliche Metriken zur Auswertung des Use Cases vorgeschlagen, die benötigten Datenquellen und Anmerkungen zur Datenbeschafftheit aufgeführt und Hinweise für eine mögliche Testauswertung des Use Cases gegeben. Bei der Auswahl eines nicht anwendbaren Use Case wird zusätzlich zu den anderen Informationen noch der Ausschlussgrund dargelegt. Dafür werden Fragen und Antworten aufgelistet, die zur Verletzung von Anwendbarkeitsbedingungen des Use Case geführt haben. Die Anwendung ermöglicht zudem das Speichern der Grafiken und der Fragebogenergebnisse in dem vom Programm angelegten Ordner „ML4FW_Fragebogen_Ausgaben“.

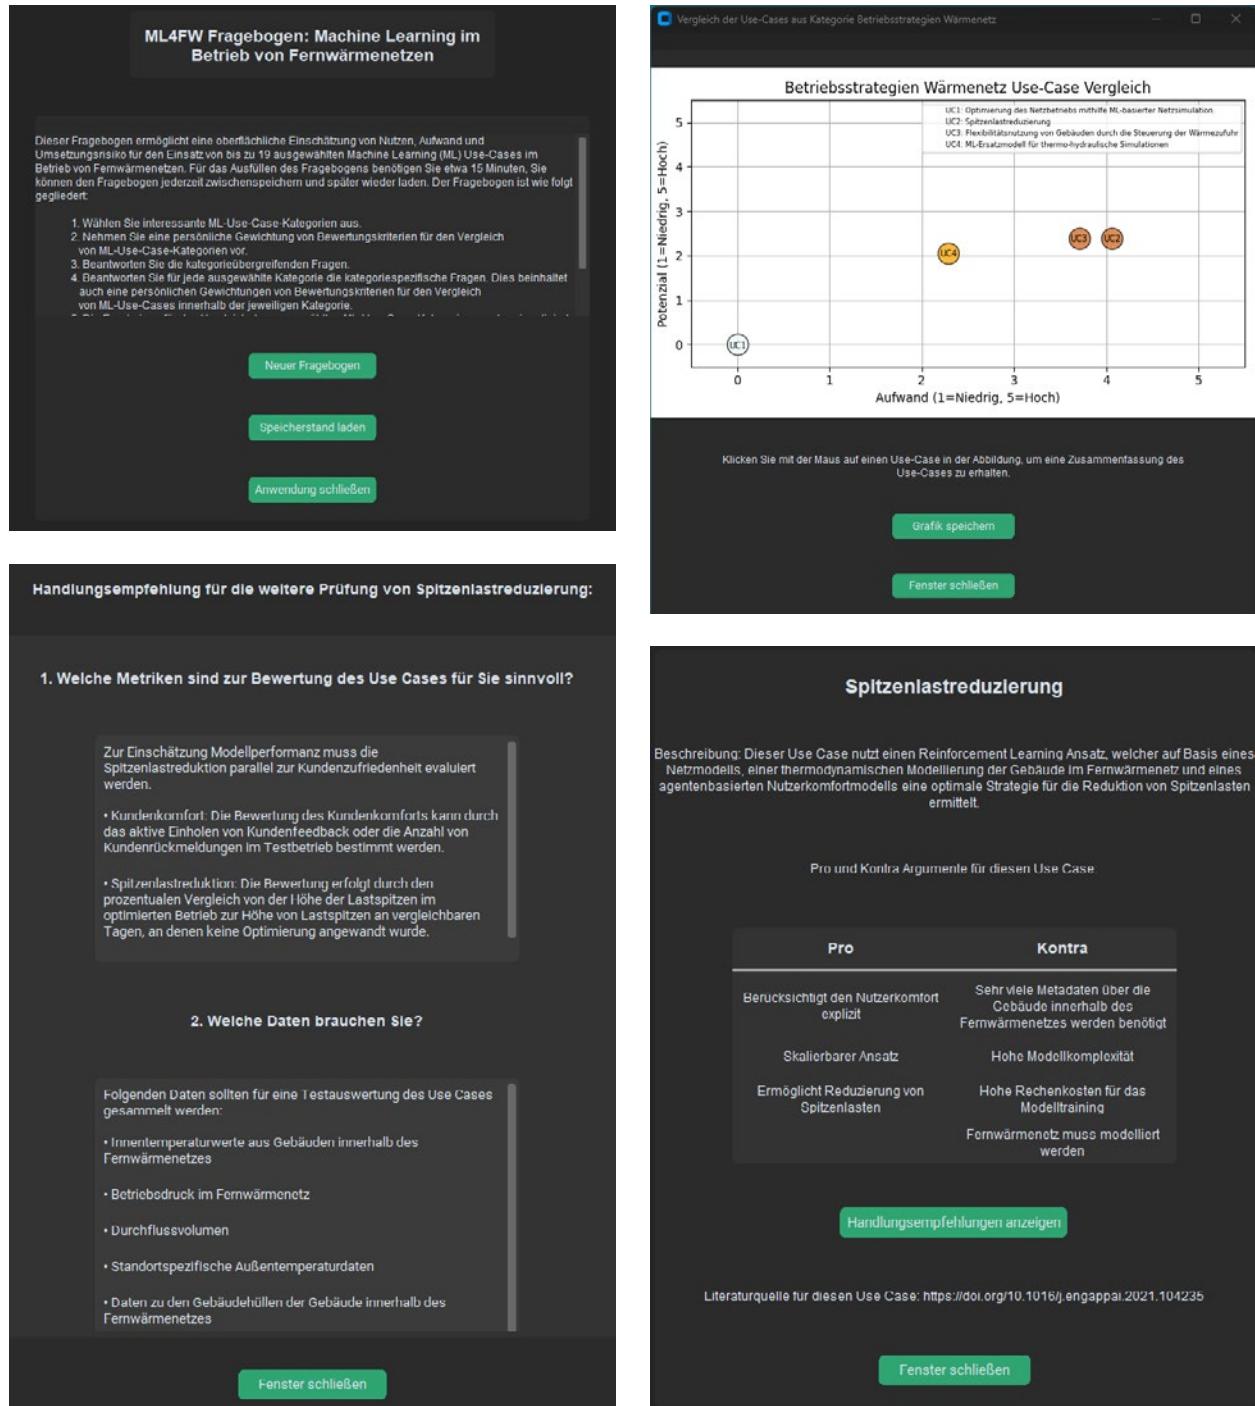


Abbildung 20: Screenshots des Startmenüs, der Ergebnisvisualisierung und der Use-Case-Zusammenfassung der Python-Anwendung zur Nutzung des Fragebogens

3.2.2 Ergebnisse der Kategorieumfrage

Für die Erstellung der Bewertungsgrundlage der Kategorievergleiche wurde eine Expertenumfrage zur Einschätzung der ML-Use-Case-Kategorien durchgeführt. Darin wurden Experten des Fraunhofer IEE, des Fraunhofer IBP, des AGFW und der dena befragt. Zusätzlich zu den fünf ML-Use-Case-Kategorien des ML4FW-Fragebogens wurde die Kategorie Betrieb der Wärmeerzeugung hinzugefügt, um eine zukünftige thematische Erweiterung des ML4FW-Fragebogens zu erleichtern und ein vollständiges Einschätzungs Bild zu ML Use Cases im Bereich des Betriebs von Fernwärmesystemen zu bekommen.

Insgesamt wurden neun Rückmeldungen gegeben, wobei zwei Formulare nur teilweise ausgefüllt wurden.

Eine Zusammenfassung der Umfrageergebnisse ist in Tabelle 5 zu sehen. Dort sind die Mittelwerte der Punktevergaben pro Kategorie und Kriterium aufgetragen, wobei fehlende Angaben ignoriert wurden. Während sich hinsichtlich des Kriteriums Energieeffizienz sowie bezüglich der Umweltauswirkungen von ML Use Cases im Betrieb der Wärmeerzeugung (BeErz) und der Hausstationen (BeHAST) deutliche Tendenzen hinsichtlich eines repräsentativen Mittelwerts ausgeprägt haben, liegt den

Mittelwerte zu den Kriterien Personal- und Zeitaufwand eine besonders große Streuung in den Daten zugrunde. Die final

resultierende Wertetabelle 8 stellt das Hintergrundwissen für die Kategorievergleiche im Rahmen des ML4FW-Fragebogens dar.

	Kosten- aufwand	Zeitaufwand	Personal- aufwand	Versorgungs- sicherheit	Umwelt- auswirkungen	Automati- sierungsgrad	Energie- effizienz
InHAST	3	4	4	4	3	3	3
InRN	3	4	4	5	3	3	3
WBP	1	2	1	2	4	5	4
BeWN	3	3	3	3	4	4	4
BeHAST	2	3	2	3	5	4	4
BeErz	4	4	3	2	4	4	4

Tabelle 4: Berechnete Mittelwerte aus den Rückmeldungen zur Kategorieumfrage (Bewertung von „1 – trifft nicht zu / niedrig“ bis „5 – trifft voll zu / hoch“)

Legende: **InHAST**: Instandhaltung Hausstationen; **InRN**: Instandhaltung Rohrleitungsnetz; **WBP**: Wärmebedarfsprognosen; **BeWN**: Betriebsstrategien Wärmenetz; **BeHAST**: Betriebsstrategien Hausstationen; **BeErz**: Betrieb Wärmeerzeugung

3.3 Exemplarische Auswertung des Use Case

Nach der Fertigstellung der Bewertungsmethode in Form einer Python-Anwendung wurde der Fragebogen von der Neuwoba ausgefüllt. Auszüge aus dieser Auswertung dienen hier der Veranschaulichung der Kategorie- und Use-Case-Bewertungen. Insgesamt ergibt sich aus der Kombination der vorgenommenen Gewichtungen der globalen Kriterien mit dem vordefinierten Kategorieranking aus Tabelle 5 der Kategorievergleich in Abbildung 21. Zum einen weist die Kategorie Wärmebedarfsprognosen (WBP) bei vergleichbarem Nutzen gegenüber der Kategorie Betriebsstrategien Wärmenetz (BeWN) einen

deutlich geringeren Aufwand und ein geringeres Umsetzungsrisiko auf. Zum anderen sind alle Use Cases in der Kategorie BeWN nicht umsetzbar, da notwendige Daten zur Umsetzung fehlen (siehe Abbildung 22 oben rechts). Die Kategorie Betriebsstrategien für Hausstationen (BeHAST) ist hinsichtlich sowohl des Aufwands als auch des Nutzens höher einzustufen als die Kategorie Instandhaltung von Hausstationen (InHAST).

Bei der Use-Case-Bewertung wird die Einordnung des BeHAST-Use-Case „ML-unterstützte Reglerparameteroptimierung“ hier exemplarisch ausgeführt.

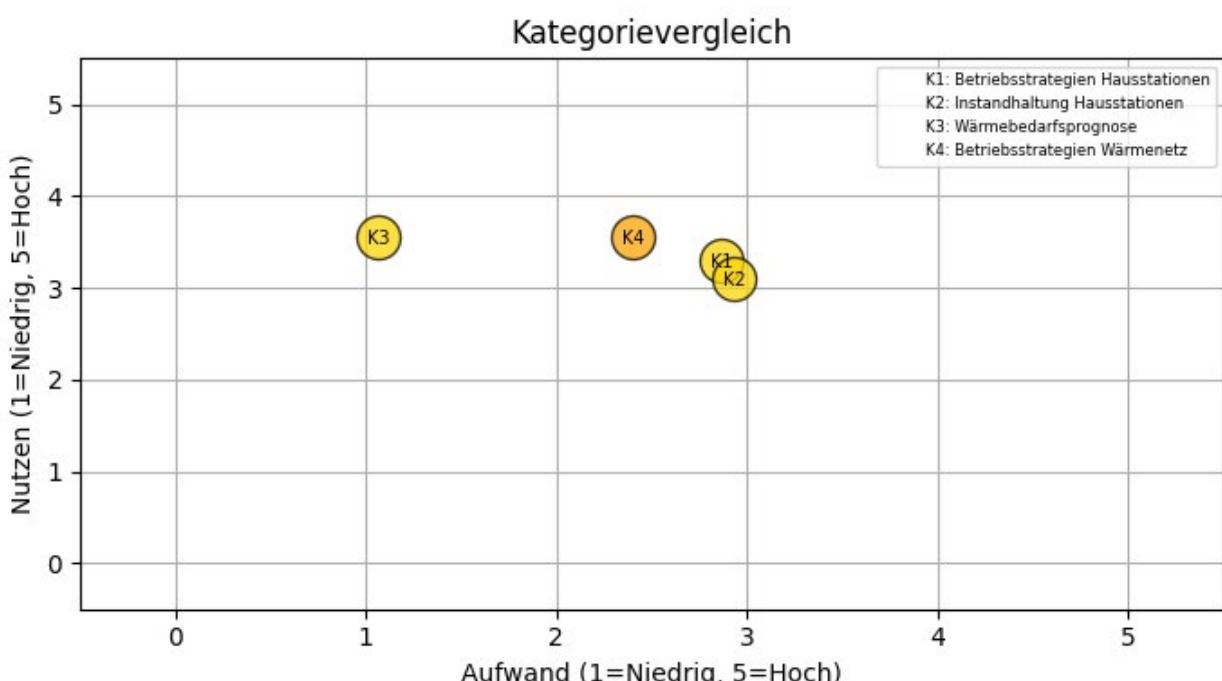


Abbildung 21: Grafische Darstellung des Kategorievergleichs der Testauswertung der Neuwoba

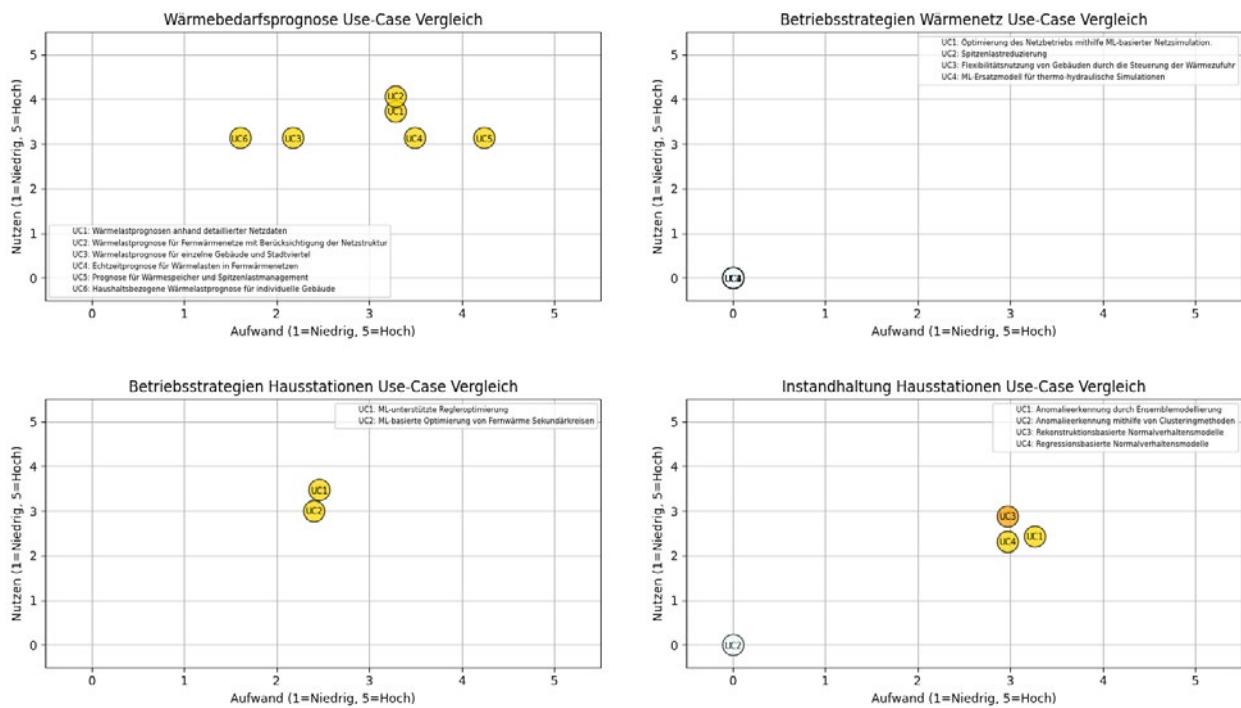


Abbildung 22: Grafische Darstellung der Use-Case-Vergleiche zu den ausgewählten Kategorien aus der Testauswertung der Neuwoba

Innerhalb der Kategorie BeHAST wird der Nutzen von Use Cases durch die Bewertungskriterien Senkung der Rücklauftemperaturen, Interpretierbarkeit der verwendeten Modelle und Berücksichtigung des Kundenkomforts bestimmt. Dafür wurden im Verlauf der Fragebogens Gewichtungen durch die Neuwoba vorgegeben und mit vordefinierten Werten kombiniert. Die vordefinierten Werte wurden in Abstimmung der Use-Case-Umsetzung und der wissenschaftlichen Begleitung des Projekts als Bewertungsgrundlage für den Fragebogen festgelegt.

Beim Punkt Senkung der Rücklauftemperaturen wurden aufgrund der Auswertungsergebnisse und der erfolgreich abgesenkten Rücklauftemperatur 4 von 5 Punkten vergeben. Hinsichtlich der Interpretierbarkeit sind die verwendeten Convolutional Neural Networks zwar zunächst als Black-Box-Methode angelegt, bieten jedoch durch die Architektur der Convolutions Anschlussmöglichkeiten für Visualisierungen und erklärbare KI-Ansätze, um die Modellentscheidungen zu durchleuchten. Zudem fließt durch die vorgenommene Simulation von Trainingsdaten interpretierbares Vorwissen in das Modell ein. Diese Abwägungen resultierten in der Vergabe von 3 von 5 Punkten. Bezuglich des

Kriteriums Kundenkomfort wurden in der Simulation der Trainingsdaten für das ML-Modell Annahmen und Einschränkungen getroffen, um den Kundenkomfort zu berücksichtigen. In Kombination mit der Kundenbefragung und dem Nichtvorliegen von Beschwerden wurden 4 von 5 Punkten vergeben. Mit den vorgenommenen Gewichtungen der Neuwoba, die alle Kriterien als etwa gleich wichtig angeben, ergibt sich so insgesamt ein Nutzen von etwa 3,5. Hinsichtlich der Einschätzung des Aufwands wurden die vordefinierten Einschätzungen aus Tabelle 6 mit den Antworten der Neuwoba zu Fragen hinsichtlich der Datenverfügbarkeit und möglicherweise notwendiger Datenerhebungen kombiniert und ergeben einen Aufwandswert von etwa 2,5. In Bezug auf das Umsetzungsrisiko wurden aufgrund des eingetretenen Risikos des verzögerten Erhalts von Daten 3 von 5 Punkten vergeben, was sich mit dem durch die Angaben der Neuwoba ermittelten Kategorierisiko von 3 deckt. Somit wird der Use Case der ML-unterstützten Reglerparameteroptimierung in dieser Auswertung mit geringem Aufwand, relativ hohem Nutzen und einem moderaten Umsetzungsrisiko bewertet. Die Zusammenfassung der Vor- und Nachteile des Use Case für den Anwender sind in Abbildung 23 zu sehen.

Kriterium	Beschreibung	Wert	Begründung
Datenaufbewahrungsaufwand	Einschätzung zum entstehenden Aufwand für die Datenspeicherung und Datenpflege	2	Das Gesamtvolumen der Trainingsdaten ist eher gering.
Kontinuierlicher Aufwand	Schätzung des ständigen Aufwands bei einem kontinuierlichen Betrieb des ML Use Case	2	Sobald das System aufgesetzt ist, können die Reglerparameter automatisch optimiert werden.
Rechenaufwand	Einschätzung des Rechenaufwands, der für die Modellerstellung entsteht	1	Das Training der Convolutional Neural Networks benötigte geringe Rechenressourcen.
Sensorinstallationsaufwand	Aufwand für die Installation neuer Sensorik	4	Falls Sensorik fehlt, ist es sehr aufwendig, sie in Hausstationen nachzurüsten.
Implementationsaufwand	Aufwand für das Implementieren der ML-Lösung	3	Die Implementierung der Modelle und des Modelltrainings war von moderatem Aufwand geprägt.
Datenerhebungsaufwand	Aufwand für das Sammeln von Daten für ein Modelltraining	5	Aufwendige Erstellung der Trainingsdatensimulation
Metadatenerhebungsaufwand	Aufwand für das Sammeln von Metadaten für die Modellierung im Rahmen des Use Case	4	Die Trainingsdatensimulation benötigt viele Metadaten.

Tabelle 5: Kriterien zur Aufwandseinschätzung von ML Use Cases im ML4FW-Fragebogen mit Beschreibung und den exemplarisch aufgeführten vordefinierten Werten für den Use Case „ML-unterstützte Reglerparameteroptimierung“ inklusive kurzer Begründung der Bewertung

ML-unterstützte Regleroptimierung

Beschreibung: Dieser Use Case nutzt die Anwendbarkeit und Effektivität von Methoden des maschinellen Lernens (ML) für das Auto- und Continuous Commissioning von Regelgeräten an realen Fernwärmehausstationen. Dafür wird die automatisierte Anpassung von Reglerparametern, die sich zunächst in der Werkseinstellung befinden, an die individuellen Betriebsbedingungen des jeweiligen Gebäudes erreicht. Dies stellt sicher, dass eine optimale Regelung der Hausstationen (HAST) erreicht wird.

Pro und Kontra Argumente für diesen Use Case:

Pro	Kontra
Senkung der Rücklauftemperatur neuen Parametersatzes für die Heizkurve	Aufwändige Simulation als Grundlage
Einfaches Einstellen der optimierten Parametersätze	Detaillierte Metadaten von mehreren HAST Komponenten werden benötigt
Anpassung des Modells an veränderte Umgebungsbedingungen ist nicht aufwendig	

[Handlungsempfehlungen anzeigen](#)

Literaturquelle für diesen Use Case: TBD

Abbildung 23: Zusammenfassung der Auswertung zum Use Case „ML-unterstützte Reglerparameteroptimierung“

3.4 Diskussion und Einordnung der Ergebnisse

Die dargestellte Bewertungsmethode ist ein erster vollständiger Entwurf einer automatisierten Einschätzungsmethodik für ML Use Cases im Fernwärmesystembetrieb. Neuartig ist dabei der Ansatz einer datenlosen Einschätzung, die von potenziellen Anwendern schnell und ohne detailliertes ML-Hintergrundwissen vorgenommen werden kann. Das Ergebnis der Anwendung ist eine erste semiquantitative Abschätzung von Nutzen, Aufwand und Risiko der selektierten ML Use Cases auf einer Skala von 1 bis 5. Damit bietet der ML4FW-Fragebogen Akteuren aus dem Fernwärmesystembetrieb eine neuartige Möglichkeit zur persönlichen Einschätzung von ML Use Cases. Unter Einbeziehung der individuellen Präferenzen und Umstände des Nutzers wird das hinterlegte Expertenwissen im Kontext der Use Cases ausgewertet und zur resultierenden Einschätzung zusammengefasst. Als Ergebnis des Projekts steht eine öffentlich nutzbare Python-Anwendung dieser Bewertungsmethode zur Verfügung, was die breite und unkomplizierte Nutzung der Bewertungsmethode ermöglicht.

Da der ML4FW-Fragebogen zum Zeitpunkt des Projektabschlusses ausschließlich innerhalb der Projekterarbeitung getestet und validiert wurde, steht noch eine Evaluation in der tatsächlichen Anwendung aus. Insbesondere Fragestellungen hinsichtlich der Formulierung und Begriffsdefinition in den Fragetexten können durch detailliertes Feedback in dedizierten Folgeprojekten verfeinert werden, wobei stets die Balance zwischen Einfachheit/Anwendbarkeit des Fragebogens und der notwendigen Spezifität/Komplexität der Fragen gewahrt werden muss.

Die entwickelte Bewertungsmethode ist ein erster Ansatz, die teils sehr heterogenen Umgebungsbedingungen in unterschiedlichsten Fernwärmesystemen möglichst gut zu vereinen und alle relevanten Hauptfaktoren in einem allgemeinen Fragebogen unterzubringen. Dieser Zusammenfassungsprozess ist im Rahmen des ML4FW-Projekts angestoßen, jedoch noch nicht abgeschlossen worden, da die resultierenden komplexen Fragestellungen größere zeitliche und personelle Ressourcen benötigen. Somit ist diese Bewertungsmethode als ein erster konkreter Anfang für weiterreichende Folgeaktivitäten zu sehen. Dazu gehört auch die im Projekt durchgeführte Kategorieumfrage, die mit neun Teilnehmern nicht repräsentativ ist. Sie stellt durch die berechneten Mittelwerte der Kategorieeinschätzungen eine mit großen Unsicherheiten behaftete, erste Einschätzung der gegebenen sechs Kategorien hinsichtlich der sieben globalen Bewertungskriterien dar. Somit ist eine gute Grundlage für die Bewertung und Einschätzung von ML Use Cases im Fernwärmesystembetrieb gegeben, es bieten sich aber auch klare Anschluss- und Verbesserungsmöglichkeiten.

3.4.1 Feedback und Verbesserungen

Auf Basis der ersten Versionen des ML4FW-Fragebogens wurde Feedback innerhalb des Projektkonsortiums eingesammelt. Durch Rückmeldungen der dena, der AGFW und der SAMSON AG erfolgten einige Verbesserungen. Dabei wurden hauptsächlich Änderungen vorgenommen, um die Aspekte Nutzerorientierung in der App, Begriffsdefinitionen und Anwendbarkeit des Fragebogens zu verbessern.

Besonders in Bezug auf Zusatzinformationen zur Einordnung und zum Verständnis von Fragen wurden Maßnahmen umgesetzt, sodass zu jeder Frage eine Infokachel verfügbar ist, die den Kontext der Frage einordnet, begründet, warum diese Frage gestellt wird, und die Auswirkungen der verschiedenen Antwortmöglichkeiten aufführt. Zusätzlich wurden besonders vor dem zentralen Element der Kriteriengewichtungen Infotexte eingefügt, die die Bedeutung dieser Fragen für den Nutzer erläutern und auf die optimale Nutzung dieser Fragen hinweisen, um die eigene Anwenderperspektive einzubringen.

Bezüglich der Anwendbarkeit des Fragebogens wurde insbesondere angemerkt, dass einige Fragen lediglich die Antworten „Ja“ oder „Nein“ zulassen, weshalb Nutzer mit Bedingungen, die keine definitive Antwort zulassen, diesen Fragebogen nur mit Einschränkungen oder gar nicht sinnvoll ausfüllen können. Dieses Konzept zu überarbeiten, würde allerdings eine aufwendige, tiefgreifende Überarbeitung des Auswertungskonzepts nach sich ziehen, die im Rahmen dieses Projekts nicht umsetzbar war.

Eine weitere Rückmeldung bezieht sich auf die Art und Weise, wie der ML4FW-Fragebogen veröffentlicht wird, da die ausführbare EXE-Datei zwar einerseits einfache Einsatzmöglichkeiten mit wenigen technischen Einschränkungen bietet, aber

andererseits für die Nutzung in Unternehmen aufgrund von IT-technischen Hürden problematisch sein kann. Aus diesem Grund ist eine Bereitstellung der Bewertungsmethodik mit dem gleichen Inhalt, aber in anderen Formaten wie beispielsweise Online-Fragebögen ebenfalls eine Möglichkeit, die Projektgebisse weiter voranzutreiben. Während der Erweiterung des ML4FW-Projekts wurde noch ein zusätzliches Übersichtsfenster für die Beschreibung von Handlungsempfehlungen auf Use Case Ebene hinzugefügt.

Derartige Überlegungen sollten in möglichen Folgeprojekten berücksichtigt werden.

3.5 Fazit und Handlungsempfehlungen zur Bewertungsmethode

Als Handlungsempfehlung ergibt sich aus diesem Projekt zunächst die Erprobung der erstellten Bewertungsmethode durch Akteure aus dem Bereich des Fernwärmesystembetriebs. Durch gezielte Einsammlung von Feedback können eine weitere Verbesserung und eine höhere Nutzerfreundlichkeit des Fragebogens sichergestellt werden.

Darüber hinaus gibt es weitere Ansätze, um das Bewertungskonzept zu verbessern und den damit einhergehenden Mehrwert zu steigern. Zum einen ist eine weitere Durchführung und Anpassung der im Projekt durchgeführten Umfrage zur Einschätzung der ML-Use-Case-Kategorien sinnvoll, um die Meinung von weiteren Expertinnen und Experten einzuholen und das Ergebnis aussagekräftiger zu gestalten. Im Einsammlungsprozess der Umfragerückmeldungen wurde festgestellt, dass die Einschätzung der Kategorien zu den gegebenen Kriterien eine größere Aufgabe darstellt und nur wenige Expertinnen und Experten alle Kategorien bezüglich jedes Themas einschätzen können. Somit ist eine Überarbeitung dieser Umfrage in zukünftigen Projekten notwendig. Darin könnte beispielsweise durch eine Konkretisierung auf detailliertere, einfacher einzuschätzende Bewertungskriterien die Beantwortbarkeit der Umfrage erhöht werden. Ein mögliches erweitertes Umfrageergebnis stabilisiert die Bewertungsgrundlage und trägt auch dazu bei, sie aktuell zu halten.

Einen weiteren Schritt zur Verbesserung der Bewertungsmethodik stellt die thematische Erweiterung des Fragebogens dar. Wie bereits in der Kategorieumfrage angelegt, wäre eine Erweiterung des Fragebogens um die Kategorie Betrieb der Wärmeerzeugung von großem Mehrwert. Zum einen werden in dieser Kategorie große Potenziale vermutet, die durch die Umsetzung von ML Use Cases gehoben werden können, zum anderen würde dies eine thematische Erweiterung vom Fernwärmesystembetrieb hin zum Betrieb ganzer Fernwärmesysteme bedeuten.

Nicht zuletzt profitiert die Bewertungsmethodik von weiteren Umsetzungsprojekten von ML Use Cases im Fernwärmesystembetrieb, deren Ergebnisse öffentlich zur Verfügung gestellt werden. Für eine Schärfung und Präzisierung der vom ML4FW-Fragebogen ausgegebenen Auswertung sind mehr Berichte und Erfahrungen aus der praktischen Umsetzung von großem Vorteil.

4 Schlussfolgerungen und Ausblick

Das in diesem Bericht dargestellte Projekt gliedert sich in zwei Bestandteile: In Projektteil 1 (Kapitel 2) wurde die Erprobung eines ML Use Case bearbeitet und in Projektteil 2 (Kapitel 3) eine Bewertungsmethodik für ML Use Cases im Fernwärmesystembetrieb entwickelt.

4.1 Schlussfolgerungen

Der im ersten Projektteil verfolgte Ansatz zeigt exemplarisch, wie mithilfe von Methoden des maschinellen Lernens Verbesserungen im Fernwärmebetrieb möglich sind. Der ausgeführte Use Case des Auto- und Continuous-Commissioning von Regelgeräten an realen Fernwärme-Hausstationen demonstriert dies exemplarisch. Unter Auto-Commissioning wird eine automatisierte Anpassung von Reglerparametern an die individuellen Betriebsbedingungen des jeweiligen Gebäudes verstanden. Dies soll sicherstellen, dass eine optimale Regelung der Hausstationen (HAST) erreicht wird. Beim Continuous-Commissioning wird zudem eine kontinuierliche Anpassung der Reglerparameter an sich verändernde Betriebsbedingungen betrachtet.

Der Projektansatz belegt ein klares Optimierungspotenzial für die Bereitstellung von optimierten Reglerparametern. Wie ausgeführt, kann eine Reduktion der Rücklauftemperaturen von HAST in der Größenordnung von 2 bis 3 K und eine Senkung der kumulierten Wärmemenge über die Vergleichstage von ungefähr 8-9 % durch diese Maßnahmen erreicht werden, was zu einer Effizienzsteigerung des Fernwärmesystembetriebs und zu einer möglichen Kostenreduktion von 0,5 bis 0,65 €/MWh*K für das FernwärmeverSORGungsunternehmen führt (siehe Averfalk et al. 2021). Dies würde bei einer Umsetzung der beschriebenen Methode auf alle Gebäude im Fernwärmennetz in Neubrandenburg mit einer jährlichen Wärmeabgabe von ca. 237 GWh eine Einsparung von ungefähr 355.000 €/a bedeuten. Für die weitere Skalierung des Verfahrens auf weitere Gebäude und Wärmenetze liegt die Herausforderung nun darin, diesen Ansatz über Einzelobjekte hinaus zu verstetigen und ihn in die Praxis übertragbar zu machen. Dynamisch adaptive Heizkurvenregelungen könnten dabei einen zentralen Baustein darstellen, insbesondere in den energetisch sensiblen Übergängen zwischen den Jahreszeiten.

Im zweiten Projektteil wurde durch die Erstellung des ML4FW-Fragebogens eine Möglichkeit geschaffen, die Digitalisierung der Fernwärme schneller voranzutreiben. Trotz des großen Potenzials von ML-Anwendungen im Fernwärmennetz werden diese nur sporadisch eingesetzt. Gründe dafür sind oftmals Unklarheit über die bestehenden Möglichkeiten und ihre Voraussetzungen. Zudem ist die Abschätzung von Mehrwerten mit hohem Aufwand verbunden.

Als Lösungsansatz für diese Probleme ermöglicht der ML4FW-Fragebogen eine datenlose, semiquantitative Einschätzung von Nutzen, Aufwand und Risiko für eine repräsentative Auswahl von Use Cases im Fernwärmesystembetrieb. Als Open-Source-EXE wird er potenziellen ML-Anwendern unkompliziert als Download bereitgestellt. Die systematische Kategorisierung der Use Cases und die Fokussierung auf wesentliche Umsetzungsaspekte

erlauben es Akteuren aus dem Fernwärmesystembetrieb, ohne tiefergehende Vorkenntnisse und mit geringem Aufwand ML-Effizienzpotenziale zu erkunden. Durch die persönlichen Kriterien-gewichtungen innerhalb des Fragebogens wird eine individuelle Priorisierung und Identifikation interessanter ML Use Cases ermöglicht, um im nächsten Schritt konkretere Detailüberlegungen zur Umsetzung anzustellen.

4.2 Lessons Learned

Die Durchführung des Use Case in Projektteil 1 hat gezeigt, dass der Erfolg von KI- und ML-Anwendungen im Fernwärmesektor weniger von komplexen Algorithmen als von sauberen Prozessen, realistischen Zeitplänen sowie einer belastbaren Daten- und IT-Basis abhängt. Aus den technischen und organisatorischen Erfahrungen lassen sich praxisnahe Empfehlungen ableiten, die zukünftige Projekte beschleunigen und typische Fallstricke vermeiden helfen. Die wichtigsten Erkenntnisse sind nachfolgend zusammengefasst.

- Realistische Zeitplanung
 - Datenaufnahme, Hardware-Nachrüstungen und Genehmigungen dauerten deutlich länger als die Modell- und Code-Entwicklung.
 - Empfehlung: Mindestens ein Pufferquartal für Sensoreinbau, Gateway-Inbetriebnahme und Datenbereinigung einplanen.
- Datenerfassung als Startpunkt
 - Die Erstellung der Datensätze gestaltete sich teilweise herausfordernd und spiegelte die typischen Probleme bei der fortschreitenden Digitalisierung von Regel- und Messsystemen wider. Eine Auflistung der aufgetretenen Probleme ist in Kapitel 2.1 zu finden.
- Datenqualität vor Modellkomplexität
 - Ein lückenfreies 1-Minuten-Logging war wertvoller als zusätzliche Messgrößen.
 - Fehlende Felder (sekundärseitiger Massenstrom, Raumtemperaturen) begrenzen die Modellgüte und Aussagekraft.
 - Erst nach mehr als einer Heizperiode mit stabilen Daten lohnt der Schritt zu komplexeren ML-Ansätzen (z. B. Reinforcement Learning).
- Frühe Einbindung aller IT- und OT-Akteure
 - SSO-, Datastore- und API-Zugriffe müssen gemeinsam mit Netz- und Gebäude-IT freigeschaltet werden, sonst blockieren scheinbare Kleinigkeiten das ganze Projekt.
- ML-Ops klein starten, dann skalieren
 - Eine schlanke Pipeline (Datastore → 1D-CNN → Gradienten-Optimierung → Regler-API) reichte für den Piloten.
 - Für den Rollout sind Versionierung und Rollback der Modelle Pflicht; in der Pilotphase noch manuell erledigt.

- Übertragbarkeit
 - Die Methode funktioniert bei baugleichen Häuserzeilen; für heterogene Bestände braucht es Templates für Heizkurven, Gebäudeklassen und Default-Parameter.
 - Ein zentrales Repository mit validierten Simulationsmodellen würde künftige Projekte beschleunigen.
- Wirtschaftlichkeit transparent machen
 - Rücklauftemperatur sinkt; monetärer Vorteil vorhanden
 - Eine frühzeitige Kommunikation dieser Einsparung erleichtert Investitionsentscheidungen für weitere Gateways.

Zusammenfassend lässt sich für den Projektteil 1 feststellen, dass eine saubere Datenbasis, klar definierte IT-Prozesse und ein schlankes, iterierbares ML-Ops-Gerüst wichtiger sind als hochkomplexe Algorithmen. Werden diese Grundlagen geschaffen, lassen sich in typischen Gebäuden nach wenigen Wochen Effizienzgewinne erzielen.

Im Rahmen der wissenschaftlichen Begleitung und der Entwicklung der Bewertungsmethode in Projektteil 2 wurde mit dem Betrieb von Fernwärmesystemen ein breites Themengebiet mit zahlreichen ML-Anwendungsmöglichkeiten und sehr inhomogenen Umsetzungsvoraussetzungen bearbeitet. Mit dem Ziel, einen einfach zu bearbeitenden Fragebogen zu erstellen, der insbesondere von Akteuren aus dem Fernwärmesystembetrieb genutzt werden kann, mussten die voraussichtliche Ausfüllzeit und damit einhergehend die Anzahl der Fragen und ihr Komplexitätslevel gering gehalten werden. Im Kontrast dazu erfordert eine akkurate Bewertung der Use Cases die Klärung vieler Detailfragen und zahlreiche Vertiefungsmöglichkeiten. Die Abwägung dieser Aspekte stellte in allen Erarbeitungsphasen stets eine prägende Herausforderung dar. Durch eine stärkere Fokussierung auf die Nutzbarkeit des Fragebogens und eine Limitierung von Diskussionen zu Detailfragen kann der Erarbeitungsprozess der Bewertungsmethode effizienter gestaltet werden.

4.3 Ausblick

Ausgehend von dem in diesem Bericht im Projektteil 1 dargestellten „Proof of Concept“ für die Nutzung von Methoden des maschinellen Lernens für die Optimierung von Hausstationen in Fernwärmesystemen stellt sich für Folgeaktivitäten die Frage, wie sich der Ansatz skalieren und somit in die Fernwärmepraxis übertragen lässt. So können die Methode und der Ansatz direkt im praktischen Fernwärmebetrieb verwendet werden und gegebenenfalls eine entsprechende Verbreitung in der Branche finden.

Um den Ansatz für die Praxis besser zugänglich zu machen, ist eine Vereinfachung der zurzeit nötigen Simulationsrechnungen für das Modelltraining wichtig. Derzeit ist die Anpassung der Simulationsmodelle, für die etliche Parameter aus den realen Anlagen wie Leitungslängen, Ventile etc. benötigt werden, für eine breite praktische Anwendung zu aufwendig (bzw. zu teuer). Ein möglicher Ansatz ist, die Modelle im Rahmen eines Meta-Learning-Prozesses (vgl. Hospedales et al. 2020) aufzusetzen und so

einen Modellsatz zu generieren, der für viele Anwendungsfälle und unterschiedliche Gebäude geeignet ist und sich durch die zu erhebenden Messdaten an die realen Gegebenheiten vor Ort anpassen lässt.

Ein weiterer Punkt bei der Weiterverfolgung des Ansatzes ist die Frage, wann ein Neutrainings der Modelle und die Generierung eines neuen Satzes Reglerparameter nötig sind. Da in dem Verfahren nicht immer ein direkter Zielwert erreicht werden muss, ist die Einschätzung, ob der Betrieb zu einem bestimmten Zeitpunkt mit dem aktuellen Parametersatz noch effizient ist oder ob gegebenenfalls ein neuer und verbesserter Parametersatz den Betrieb aktuell weiter verbessern kann, nicht trivial. Eine Einbindung von Informationen über Raumtemperaturen in den Wohnungen und Komfortbedingungen, die eingehalten werden müssen, können die Funktionalität weiter verbessern. Die klassischen Methoden der Anomalieerkennung greifen hier nicht, da der jeweilige optimale Betriebszustand von zu vielen nicht erfassten Umwelt- und Systembedingungen abhängt. Der Ansatz eines adaptiven Betriebs durch eine permanente Nachjustierung der Reglerparameter ist nicht praktikabel, da dazu eine permanente und sichere Datenverbindung nötig ist. Beim realen Einsatz in Gebäuden kann es immer wieder zu Konnektivitätsproblemen kommen, was die Anwendung eines solchen Ansatzes unmöglich macht. Der hier vorgeschlagene Ansatz ist robuster im Einsatz, da nur die neuen Reglerparameter übertragen werden und die Anlage sonst auch ohne eine Datenanbindung optimiert läuft.

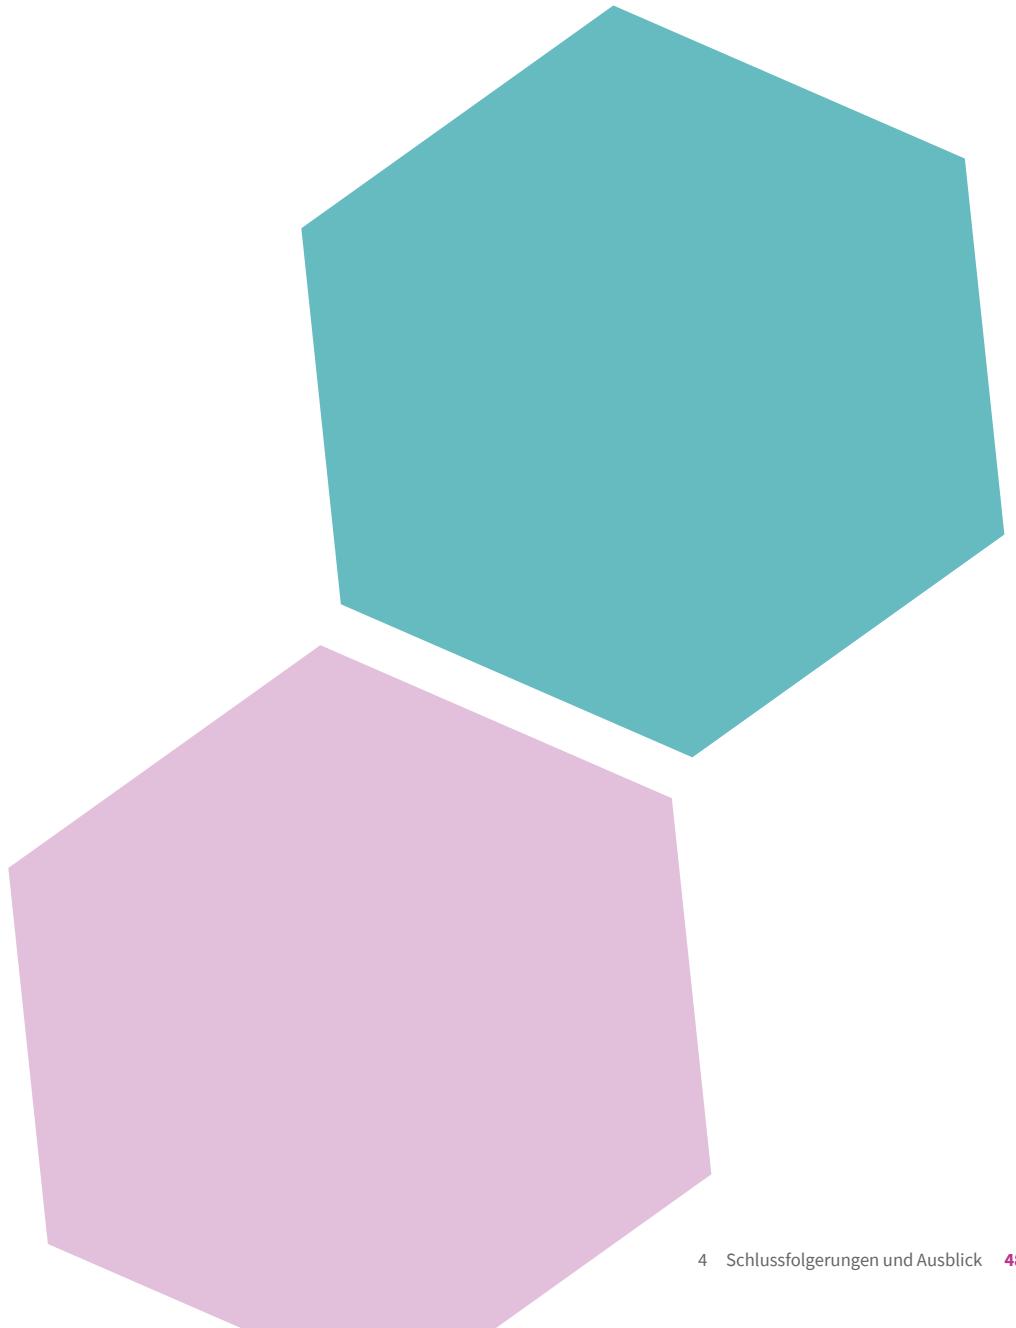
Ein weiterer Punkt für eine weitere Bearbeitung ist die Frage nach dem Business-Konzept für den Einsatz der Methode. Wer würde die Leistungen anbieten und welche Art von Produkt- und Preisgestaltung ist hier vonnöten? Welche Kosten fallen wo an und wer hat die Vorteile? Es ist gut vorstellbar, dass sich die Fernwärmesystembetreiber als Anbieter eignen und ihren Kunden, der Wohnungswirtschaft, eine Dienstleistung anbieten können. Mit einem direkten Zugriff auf die Fernwärmeregler könnten Wärmenetzbetreiber die Flexibilitäten des Netzes und der Gebäude besser nutzen und so gegebenenfalls teure Spitzenlastzeuge einsparen. Für die Wohnungswirtschaft wäre eine Art Post-Commissioning Check in einem Kampagnenbetrieb (zum Beispiel einmal auf Anfrage etc.) der Reglerparameter vorteilhaft, auch wäre mit den erhobenen Daten ein Abgleich zwischen bestellter und tatsächlich nötiger vertraglich vereinbarter Wärmeleistung machbar. So können die Tarife für die Wärmelieferungen angepasst und es kann eine Optimierung der Fixkosten des Fernwärmemanschlusses erreicht werden. In der Praxis zeigt sich, dass oft zu hohe Leistungen bestellt werden, was die Wärmekosten für die Mieterschaft und die Gebäudeeigentümer in die Höhe treibt.

Hinsichtlich der in Projektteil 2 erarbeiteten Bewertungsmethoden ergeben sich ebenfalls einige Anschlussmöglichkeiten wie beispielsweise die Erweiterung der expertenbasierten Umfrage, um die Wissensgrundlage für den Fragebogen auszuweiten und repräsentativer zu gestalten. Die Open-Source-Veröffentlichung

schafft darüber hinaus Raum für Weiterentwicklungen – etwa durch zusätzliche Detaillierung der Handlungsempfehlungen für den Einstieg in die Detailanalyse und die letztendliche Umsetzung von ML Use Cases.

Nicht zuletzt profitiert die Bewertungsmethodik von weiteren Umsetzungsprojekten von ML Use Cases im Fernwärmesystembetrieb, deren Ergebnisse öffentlich zur Verfügung gestellt werden. Für eine Schärfung und Präzisierung der vom ML4FW-Fragebogen ausgegebenen Auswertung sind mehr Berichte und Erfahrungen aus der praktischen Umsetzung von großem Vorteil.

Die hier ausgeführten Ergebnisse des Projekts belegen eindrücklich, welche Möglichkeiten Machine Learning für Anwendungen in der Fernwärmepraxis bietet, und zeigen beispielhaft, wie diese erfolgreich umgesetzt werden können. Weiterhin stellt die entwickelte Bewertungsmethode für ML Use Cases eine Basis für die schnelle Beurteilung eines möglichen Einsatzes dieser Konzepte dar.



Abbildungsverzeichnis

Abbildung 1:	Konsortium und Zusammenarbeit in den beiden Teilvorhaben des Projekts	14
Abbildung 2:	Gesamtsystemarchitektur für die Realisierung des Use Case	16
Abbildung 3:	Schematische Darstellung des Simulationsmodells	18
Abbildung 4:	Beispielhafter Vergleich der simulierten Rücklauftemperaturen mit den vorherigen (original: $m = 0,7$, Niveau = 3,0) und den angepassten (optimiert: $m = 0,6$, Niveau = 0,0) Reglereinstellungen vom 15.12.2024 bis 20.12.2024	19
Abbildung 5:	Vorhersagen des CNN auf dem Testdatensatz	21
Abbildung 6:	Beispielgebäude in der Petrosawodsker Straße 66-72, Neubrandenburg	22
Abbildung 7:	Schaltbild der Hausstation des Beispielgebäudes in SAM DISTRICT ENERGY	23
Abbildung 8:	Regler TROVIS 5578 der Firma SAMSON	23
Abbildung 9:	Steigungskennlinie des Reglers der Firma SAMSON entsprechend der Reglergleichung. Die Einstellungen vor und nach der Optimierung sind hervorgehoben.	24
Abbildung 10:	Außenlufttemperaturen, 15.12.2024, 30.03.2025 und 28.11.2025	26
Abbildung 11:	Außenlufttemperaturen 15.12.2024, 30.03.2025 und 28.11.2025 und der zwei vorherigen Tage	27
Abbildung 12:	Primäre Rücklauftemperaturen Petrosawodsker Straße 66-72 15.12.2024, 30.03.2025 und 28.11.2025	27
Abbildung 13:	Histogramm der Rücklauftemperaturabsenkung (primär) Petrosawodsker Straße 66-72 15.12.2024 im Vergleich zu 30.03.2025 und 28.11.2025	28
Abbildung 14:	Leistungsabnahme im Tagesverlauf Petrosawodsker Straße 66-72, 30.03.2025 und 28.11.2025	28
Abbildung 15:	kumulierte Wärmemenge Petrosawodsker Straße 66-72, 15.12.2024, 30.03.2025 und 28.11.2025	29
Abbildung 16:	Streudiagramm der Tagesmittelwerte der Außentemperatur (x-Achse) und der primären Rücklauftemperatur (y-Achse) der Zeiträume 1-3 der Petrosawodsker Straße 66-72 inkl. Regressionsgeraden	30
Abbildung 17:	Streudiagramm der Tagesmittelwerte der Außentemperatur (x-Achse) und der primären Rücklauftemperatur (y-Achse) der Petrosawodsker Straße 42-48 (Frühjahr und Winter), Petrosawodsker Straße 10-16 (Winter), Petrosawodsker Straße 18-24 (Winter)	31
Abbildung 18:	Zweistufiges Konzept für die Bewertung von ML Use Cases	36
Abbildung 19:	Schematische Darstellung des Erstellungsprozesses des Fragebogens zur Bewertungsmethode	37
Abbildung 20:	Screenshots des Startmenüs, der Ergebnisvisualisierung und der Use-Case-Zusammenfassung der Python-Anwendung zur Nutzung des Fragebogens	40
Abbildung 21:	Grafische Darstellung des Kategorievergleichs der Testauswertung der Neuwoba	41
Abbildung 22:	Grafische Darstellung der Use-Case-Vergleiche zu den ausgewählten Kategorien aus der Testauswertung der Neuwoba	42
Abbildung 23:	Zusammenfassung der Auswertung zum Use Case „ML-unterstützte Reglerparameteroptimierung“	43

Tabellenverzeichnis

Tabelle 1:	Ergebnis der Modellvalidierung	19
Tabelle 2:	Kriterien der ausgewählten Vergleichstage	25
Tabelle 3:	Rechnerische Energieeinsparung Petrosawodsker 66-72, für die spezifische Situationen an den Tagen 15.01.2024 gegenüber 30.03.2025 und 28.11.2025	29
Tabelle 4:	Berechnete Mittelwerte aus den Rückmeldungen zur Kategorieumfrage (Bewertung von „1 – trifft nicht zu / niedrig“ bis „5 – trifft voll zu / hoch“)	41
Tabelle 5:	Kriterien zur Aufwandseinschätzung von ML Use Cases im ML4FW-Fragebogen mit Beschreibung und den exemplarisch aufgeführten vordefinierten Werten für den Use Case „ML-unterstützte Reglerparameteroptimierung“ inklusive kurzer Begründung der Bewertung	43
Tabelle 6:	Ausgewählte Use Cases für die Bewertungsmethode zur Einschätzung von ML Use Cases im Fernwärmennetzbetrieb (Fortsetzung nächste Seite)	55
Tabelle 7:	Fernwärme-Preisgestaltung der Neubrandenburger Stadtwerke GmbH, Stand 2025	57
Tabelle 8:	Im Vorhaben benötigte Datenpunkte	57

Literaturverzeichnis

AGEB (2025). Anwendungsbilanzen zur Energiebilanz Deutschland - Endenergieverbrauch nach Energieträgern und Anwendungszwecken. AG Energiebilanzen e.V., Berlin.

Averfalk et al. (2021): Low-Temperature Heating Implementation Guidebook. IEA DHC Annex TS2 Bericht, Fraunhofer Verlag.

Baugenossenschaft Wiederaufbau (2025). Ende der Einrohrheizung - Ready for 2045. Homepage: <https://baugenossenschaft-wiederaufbau.de/artikelansicht/2-2023/ende-der-einrohrheizung.html>. Zugriff am 06.08.2025.

Boussaid, T., Scuturici, V.M., Rousset, F., Clausse, M. (2023). An End to-End Machine Learning Framework for District Heating Networks Simulation
<https://hal.science/hal-04462676v1>

Chatterjee, S., Bayer, S. & Maier, A. (2021) Prediction of Household-level Heat-Consumption using PSO enhanced SVR Model. arXiv.
<https://doi.org/10.48550/arXiv.2112.01908>

Claessens, B., J., Vanhoudt, D., Desmedt, J. & Ruelens, F. (2018). Model-free control of thermostatically controlled loads connected to a district heating network. Energy and Buildings, Bd. 159, S. 1–10.
<https://doi.org/10.1016/j.enbuild.2017.08.052>

Deutsche Energie Agentur (Hrsg.) dena (2024). KI in der Fernwärme: Ein Leitfaden zur erfolgreichen Umsetzung von KI-Projekten. Deutsche Energie-Agentur, Berlin.

Hospedales, T., Antoniou, A., Micaelli, P., & Storkey, A. (2020). Meta-Learning in Neural Networks: A Survey. Cornell University. arXiv:2004.05439.

Van Dreven, J., Cheddad, A., Alawadi, S., Ghazi, A., N., Al Koussa, J. & Vanhoudt, D. (2024) SHEDAD: SNN-Enhanced District Heating Anomaly Detection for Urban Substations. 9th International Conference on Fog and Mobile Edge Computing (FMEC), Malmö, Sweden: IEEE, S. 130–137.
<https://doi.org/10.1109/FMEC62297.2024.10710205>

Farouq, S., Byttner, S., Bouguelia, M., R. & Gadd, H. (2022). A conformal anomaly detection based industrial fleet monitoring framework: A case study in district heating, Expert Systems with Applications, Bd. 201, S. 116864.
<https://doi.org/10.1016/j.eswa.2022.116864>

De Giul L., B., La Bella, A. & Scattolini, R. (2024). Physics-Informed Neural Network Modeling and Predictive Control of District Heating Systems. IEEE Trans. Contr. Syst. Technol., Bd. 32, Nr. 4, S. 1182–1195.
<https://doi.org/10.1109/TCST.2024.3355476>

Hua, P., Wang, H., Xie, Z. & Lahdelma, R. (2024) District heating load patterns and short-term forecasting for buildings and city level. Energy, Bd. 289, S. 129866
<https://doi.org/10.1016/j.energy.2023.129866>

Huang, Y., Zhao, Y., Wang, Z., Liu, X., Liu, H. & Fu, Y. (2023). Explainable district heat load forecasting with active deep learning. Applied Energy, 350
<https://doi.org/10.1016/j.apenergy.2023.121753>

Ji W., H., Lee, H. & Hwang, I. (2023) Supervised learning-based classification of acoustic emission and vibration signal for identifying condition change of district heating system. *Measurement*, Bd. 220, S. 113388.
<https://doi.org/10.1016/j.measurement.2023.113388>

LeCun, Y., Bottou, L. Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86 (119, 2278-2323).
<https://doi.org/10.1109/5.726791>

Mathworks (2025). Simulink. Homepage: <https://mathworks.com/products/simulink.html>. Zugriff am 27. 08.2025.

Mathworks (2025a). Simscape. Homepage: <https://www.mathworks.com/products/simscape.html>. Zugriff am 04. 08.2025.

Mbiydzenyuy, G. et al (2021). Opportunities for Machine Learning in District Heating. *Applied Science*. 11 (13, 6112)
<https://doi.org/10.3390/app11136112>

Al Koussa, J., Måansson, S. (2022) Fault detection in district heating substations: a cluster-based and an instance-based approach. *CLIMA 2022 Conference*.
<https://doi.org/10.34641/clima.2022.45>

Renuke, A., Vouros, S. & Kyprianidis, K. (2023). Machine learning assisted adaptive heat load consumption forecasting in district heating network. *Linköping Electronic Conference Proceedings*, 200, 1-8.
<https://doi.org/10.3384/ecp200050>

Schmidt, Dietrich (ed.) et al. (2023): Guidebook for the Digitalisation of District Heating: Transforming Heat Networks for a Sustainable Future, Final Report of DHC Annex TS4. ISBN 3-89999-096-X. AGFW Project Company, Frankfurt am Main, Germany.

Techem (2025). Zahl des Tages: Mit künstlicher Intelligenz den Energieverbrauch um 29 Prozent reduzieren. Homepage: <https://www.techem.com/corp/de/news-und-medien/pressemitteilungen/mit-ki-den-energieverbrauch-um-29-prozent-senken#:~:text=Zahl%20des%20Tages:%20Mit%20k%C3%BCnstlicher%20Intelligenz%20den,29%20%25%20weniger%20Energieverbrauch%20durch%20geringinvestive%20L%C3%BClung>. Zugriff am 06.08.2025.

Solinas, F., M., Bottaccioli, L., Guelpa, E., Verda, V. & Patti, E. (2021) Peak shaving in district heating exploiting reinforcement learning and agent-based modelling. *Engineering Applications of Artificial Intelligence*, Bd. 102, S. 104235.
<https://doi.org/10.1016/j.engappai.2021.104235>

Trabert, U., Pag, F., Orozaliev, J., Jordan, U. & Vajen, K. (2024). Peak shaving at system level with a large district heating substation using deep learning forecasting models. *Energy*, Bd. 301, S. 131690,
<https://doi.org/10.1016/j.energy.2024.131690>

Vollmer, E., Ruck, J., Volk, R. & Schultmann, F. (2024). Detecting district heating leaks in thermal imagery: Comparison of anomaly detection methods. *Automation in Construction*, 165, 105543.
<https://doi.org/10.1016/j.autcon.2024.105709>

Xue, P., Jiang, Y., Zhou, Z., Chen, X., Fang, X. & Liu, J. (2020). Machine learning-based leakage fault detection for district heating networks. *Applied Energy*, 277, 115546.
<https://doi.org/10.1016/j.enbuild.2020.110161>

Zdravković, M., Mihajlović, V., Nikolić, V., & Milinković, D. (2021). Towards explainable AI-assisted operations in District Heating Systems. *Energy Reports*, 7, 3211-3218.
<https://doi.org/10.1016/j.ifacol.2021.08.044>

Zdravković, M., Ćirić, I. & Ignjatović, M. (2022). Explainable heat demand forecasting for the novel control strategies of district heating systems. *Annual Reviews in Control*, 53, 405-413.
<https://doi.org/10.1016/j.arcontrol.2022.03.009>

Zhang F. & Fleyeh, H. (2020) Anomaly Detection of Heat Energy Usage in District Heating Substations Using LSTM based Variational Autoencoder Combined with Physical Model. 15th IEEE Conference on Industrial Electronics and Applications (ICIEA), Kristiansand, Norway: IEEE, S. 153–158.
<https://doi.org/10.1109/ICIEA48937.2020.9248108>

Zheng, Y., Liu, Q., Chen, E., Ge, Y., & Zhao, J. (2014). Time series classification using multi-channels deep convolutional neural networks. In: International Conference on Web-Age Information Management (WAIM).
https://link.springer.com/chapter/10.1007/978-3-319-08010-9_33

Zhong, W., Feng, E., Lin, X. & Xie, J. (2022) Research on data-driven operation control of secondary loop of district heating system. *Energy*, Bd. 239, S. 122061.
<https://doi.org/10.1016/j.energy.2021.122061>

Abkürzungsverzeichnis

ADAM	Adaptive Moment Estimation
ANN	Artificial Neural Network
API	Application Programming Interface
BeErz	Betrieb Wärmeerzeugung
BeHAST	Betriebsstrategien Hausstationen
BeWN	Betriebsstrategien Wärmenetz
CNN	Convolutional Neural Network
CSV	Comma Separated Values
EXE	Ausführbare Datei
GUI	Graphical User Interface
HAST	Hausstation
InHAST	Instandhaltung Hausstationen
InRN	Instandhaltung Rohrleitungsnetz
JSON	JavaScript Object Notation
KI	Künstliche Intelligenz
LSTM	Long Short-Term Memory Network
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
ML	Machine Learning / Maschinelles Lernen
ML-Ops	Machine Learning Operations
MLP	Multilayer Perceptron
MSE	Mean Squared Error
REST	Representational State Transfer
SSO	Single Sign-on
TWW	Trinkwarmwasser
WBP	Wärmebedarfsprognose
WBS	Wohnungsbauserie
WMZ	Wärmemengenzähler

Anhang

Name des Use Case	Beschreibung	Quelle	Kategorie
Wärmelastprognosen anhand detaillierter Netzdaten	Wärmelastvorhersage für gesamtes Fernwärmennetz mithilfe von mehreren LSTM-Architekturen	https://doi.org/10.1016/j.arcontrol.2022.03.009 und https://doi.org/10.1016/j.ifacol.2021.08.044	WBP
Wärmelastprognose für Fernwärmenetze mit Berücksichtigung der Netzstruktur	Prognose eines Gesamtnetzes anhand der Wärmelastprofile einzelner Gebäude und der Netzwerktopologie mit Graph Recurrent Neural Networks	https://doi.org/10.1016/j.apenergy.2023.121753	WBP
Wärmelastprognose für einzelne Gebäude und Stadtviertel	Kurzfristige Lastprognose anhand historischer Last- und Wetterdaten mithilfe von ANN in Kombination mit multipler linearer Regression	https://doi.org/10.1016/j.energy.2023.129866	WBP
Echtzeitprognose für Wärmelasten in Fernwärmenetzen	Kurzfristige Wärmelastprognosen in Echtzeit mithilfe von LSTM	https://doi.org/10.3384/ecp200050	WBP
Prognose für Wärmespeicher und Spitzenlastmanagement	Vorhersage der Wärmelasten und Speicherfüllstände zur Spitzenlastkappung mit Incremental Learning LSTM	https://doi.org/10.1016/j.energy.2024.131690	WBP
Haushaltsbezogene Wärmelastprognose für individuelle Gebäude	Wärmebedarfsprognose auf Haushaltsebene mithilfe von Support Vector Regression (SVR) und Partikelschwarmoptimierung (PSO)	https://arxiv.org/pdf/2112.01908.pdf	WBP
Anomalieerkennung durch Ensemble-Modellierung	Dieser Use Case setzt einfache ML-Modelle für jede einzelne Hausstation ein und führt parallel dazu ein Clustering der Hausstationen in verschiedene Gruppen durch. Auf Basis dieser beiden Informationslevel kann ein Ensemble-Modell erstellt werden, das das Erkennen von fehlerhaften Hausstationen ermöglicht.	https://doi.org/10.1016/j.eswa.2022.116864	InHAST
Anomalieerkennung mithilfe von Clustering-Methoden	Durch die Anwendung von Clustering-Verfahren auf Basis von Zeitreihendaten der HAST werden Ausreißer-HAST identifiziert.	https://doi.org/10.1109/FMEC62297.2024.10710205	InHAST
Rekonstruktionsbasierte Normalverhaltensmodelle	In diesem Use Case wird auf Basis der Wärmeleistungsdaten das Erkennen von Abweichungen vom normalen Verhalten von HAST durch die Anwendung von rekonstruktionsbasierten Normalverhaltensmodellen wie beispielsweise Autoencodern ermöglicht. Sie erlernen das normale Verhalten auf Basis von historischen Daten der HAST.	https://doi.org/10.1109/ICIEA48937.2020.9248108	InHAST
Regressionsbasierte Normalverhaltensmodelle	Durch die Nutzung regressionsbasierter Modelle wird das Verhalten von HAST basierend auf einem bereitgestellten Datensatz erlernt. Durch den Abgleich von weiteren Betriebsdaten mit der Modellvorhersage wird die Erkennung von Abweichungen und Fehlern ermöglicht.	https://doi.org/10.34641/clima.2022.45	InHAST
Leckagenerkennung auf Basis von Infrarotbildern	Automatisierte ML-Bildanalyseverfahren werden genutzt, um Leckagen auf Infrarotbildern zu lokalisieren.	https://doi.org/10.1016/j.autcon.2024.105709	InRN

Tabelle 6: Ausgewählte Use Cases für die Bewertungsmethode zur Einschätzung von ML Use Cases im Fernwärmennetzbetrieb (Fortsetzung nächste Seite)

Name des Use Case	Beschreibung	Quelle	Kategorie
Leckagenerkennung auf Basis von Drucksensorik	Eine Kombination aus einer hydraulischen Simulation und einem auf XGBoost basierenden Klassifikator wird genutzt, um Leckagen zu identifizieren und dem korrekten Abschnitt des Rohrnetzes zuzuordnen.	https://doi.org/10.1016/j.enbuild.2020.110161	InRN
Klassifikation von Rohrzuständen auf Basis von Akustik- und Vibrationssignalen	Dieser Use Case nutzt direkte Klassifikationsverfahren wie beispielsweise Support Vector Machines für die Zuordnung von akustischen Messwerten zu festgelegten Rohrzuständen.	https://doi.org/10.1016/j.measurement.2023.113388	InRN
Optimierung des Netzbetriebs mithilfe ML-basierter Netzsimulation	Durch die Verwendung eines Reinforcement-Learning-Ansatzes in Kombination mit Hintergrundwissen über die Netztopologie wird ein effizientes und dynamisches Simulationsmodell erstellt, das anschließend verwendet wird, um den Fernwärmennetzbetrieb hinsichtlich der Kosten der Wärmeproduktion und der Wärmeeffizienz zu optimieren.	https://doi.org/10.1109/TCST.2024.3355476	BeWN
Spitzenlastreduktion	Dieser Use Case nutzt einen Reinforcement-Learning-Ansatz, der auf Basis eines Netzmodells, einer thermodynamischen Modellierung der Gebäude im Fernwärmennetz und eines agentenbasierten Nutzerkomfortmodells eine optimale Strategie für die Reduktion von Spitzenlasten ermittelt.	https://doi.org/10.1016/j.engappai.2021.104235	BeWN
Flexibilitätsnutzung von Gebäuden durch die Steuerung der Wärmezufuhr	In diesem Use Case wird ein Reinforcement-Learning-Algorithmus verwendet, um thermostatgesteuerte Wärmespeichermöglichkeiten wie Gebäudehüllen im Fernwärmennetz zu flexibilisieren. Ziel ist die Nutzung dieser Flexibilitäten für Spitzenlastreduktionen und/oder Energie-Arbitrage.	https://doi.org/10.1016/j.enbuild.2017.08.052	BeWN
ML-Ersatzmodell für thermo-hydraulische Simulationen	Dieser Use Case verwendet ein Graph Neural Network, um bestehende aufwendige thermo-hydraulische Simulationsmodelle durch ein schnelleres, effizienteres ML-Modell zu ersetzen sowie Durchflussraten und Temperaturen an verschiedenen Stellen im Netz zu simulieren.	https://hal.science/hal-04462676v1	BeWN
ML-unterstützte Reglerparameter-optimierung	Der in ML4FW erprobte Use Case	Abschlussbericht / Open-Source-Veröffentlichung	BeHAST
ML-basierte Optimierung von Fernwärme-Sekundärkreisen	Dieser Use Case befasst sich mit der Erstellung eines ML-Modells für die optimierte Steuerung des Wärmeflusses vom Primärkreislauf in den Sekundärkreislauf durch die automatisierte Steuerung von Ventilen. Das Ventilsteuerungsmodell wird dabei auf Basis historischer Ventileinstellungsdaten im Kontext mit den Wetterdaten erstellt und mit einem ML-Vorhersagemodell für die Vorlauftemperatur im Sekundärkreis bei verschiedenen Ventileinstellungen kombiniert.	https://doi.org/10.1016/j.energy.2021.122061	BeHAST

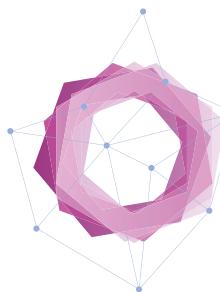
Fortsetzung Tabelle 6: Ausgewählte Use Cases für die Bewertungsmethode zur Einschätzung von ML Use Cases im Fernwärmennetzbetrieb

Arbeitspreis	Emissionspreis	MwSt.	Bruttopreis
11,27 Cent/kWh	1,55 Cent/kWh	19 %	15,26 Cent/kWh

Tabelle 7: Fernwärme-Preisgestaltung der Neubrandenburger Stadtwerke GmbH, Stand 2025
Quelle: https://www.neu-sw.de/downloads/privatkunden/produkte/fernwaerme/preisbestimmungen_fernwaerme.pdf

Art der Information	Name Datenpunkt in SAM DISTRICT ENERGY	Beschreibung Datenpunkt
Temperatur-Messwerte	Primär Vorlauftemperatur vor beiden PWT RÜF3	Temperatur Vorlauf primär
	Heizung Sekundär Vorlauftemperatur hinter der Pumpe VF1	Temperatur Vorlauf Heizung sekundär Istwert
	Heizung Sekundär Rücklauftemperatur VF4	Temperatur Rücklauf Heizung sekundär
	WWB Warmwassertemperatur VF2	Temperatur sekundär Vorlauf Warmwasser
	Primär RL, hinterm PWÜ-WWB (Rücklauftemperatur RÜF2)	Temperatur primär Rücklauf Warmwasser
	Außentemperatur AF1	Außentemperatur
Aktuelle Sollwerte	Vorlaufsollwert HK1	Temperatur Vorlauf Heizung sekundär Sollwert
	Raumsoll Aktuell HK1	Raumsoll aktuell Heizkreis 1
Zustand Pumpe	UP1	Zustand Pumpe Heizung (Ein/Aus)
	Speicherladepumpe SLP	Zustand Speicherladepumpe (Ein/Aus)
Ventil-Stellsignale	Stellsignal HK1	Position Ventil Heizung (%)
	Stellsignal HK2	Position Ventil Warmwasser (%)
Betriebsmodi	Betriebsart HK1	Betriebsart Heizkreis 1 (Tag/Nacht/Standby)
Reglerparameter	Heizkennlinie Steigung	Heizkennlinie Steigung
	Heizkennlinie Niveau	Heizkennlinie Niveau
	Raumsoll Tag HK1	Raumsoll Tag Heizkreis 1
	Raumsoll Nacht HK1	Raumsoll Nacht Heizkreis 1
Statuswerte	Fehlerstatusregister	Fehlerstatus
Wärmemengenzähler-Daten	WMZ Arbeit	Arbeit akkumuliert in MWh
	WMZ Leistung	Aktueller Leistungsmesswert in kW
	WMZ Durchfluss	Aktueller Durchflussmesswert in l/h
	WMZ Volumen	Akkumuliertes Volumen in m³
	WMZ Vorlauftemperatur	Am WMZ gemessene Vorlauftemperatur in °C
	WMZ Rücklauftemperatur	Am WMZ gemessene Rücklauftemperatur in °C

Tabelle 8: Im Vorhaben benötigte Datenpunkte



**Future Energy
Lab**

Ein Projekt der

dena