

## **BestHeatNet – Selbstlernende Betriebsoptimierung einer hybriden Nahwärmeversorgung**

**Prof. Dr.-Ing. Mario Adam, M.Sc. Jonas Gottschald,  
M.Sc. Marius Reich, M.Sc. Dennis Götzelmann**

ZIES Zentrum für Innovative Energiesysteme / Hochschule Düsseldorf

**Keywords:** Nahwärme, Künstliche Intelligenz, Flexibilität, Optimierung, Sektorkopplung

### **Zusammenfassung**

Das vom BMWi geförderte Forschungsvorhaben BestHeatNet befasst sich mit der praxisnahen Entwicklung und Erprobung eines intelligenten Optimierungs- und Regelungsverfahrens für ein hybrides Niedertemperatur-Nahwärmesystem mit hohem erneuerbaren Energieanteil und mehreren Wärme- und Stromerzeugern zur Steigerung der Energieeffizienz, der Wirtschaftlichkeit und der Systemdienlichkeit. Es ist geplant, künstliche neuronale Netze (KNN) als Basis für die Regel- und Steuerung einzusetzen. Im Gegensatz zur starren mathematischen Abbildung sind KNN in der Lage, sich flexibel an sich verändernde Randbedingungen anzupassen und so eine zuverlässige Bestimmung des optimalen Betriebs zu ermöglichen. Für ein Initialtraining der KNN wurde ein Systemmodell der derzeit im Bau befindlichen Heizzentrale erstellt. Die mit den Simulationsergebnissen trainierten (Bayesian Regularisation) KNN zeigen bereits eine hohe Prognosegüte.

### **1. Einleitung**

Die Wärmeversorgung der Zukunft wird sich ebenso wie die Stromversorgung durch einen steigenden Anteil erneuerbarer Energien auszeichnen. Aufgrund der Fluktuation erneuerbarer Energien wegen wechselnder Wetterverhältnisse ist eine hohe Flexibilität gefragt. Diese Flexibilität wird im vom BMWi geförderten Forschungsprojekt BestHeatNet erprobt. Die Wärmeversorgung für das bereits im Bau befindliche Quartier „Auf dem Zanger“ in Kempen mit rund 130 Wohneinheiten wird hierfür für 5 Jahre zum Reallabor. Solarthermie, PowerToHeat mit Elektrowärmepumpe mit Erdsonden und Elektroheizstab, Kraft-Wärme-Kopplungs-Anlage, ein Spitzenlastkessel und eine Photovoltaik-Anlage mit Batterie produzieren zukünftig benötigte Wärme und Strom aus unterschiedlichen Energiequellen. Der Erneuerbare Energien Anteil aus lokaler Produktion soll rund 30% betragen und ließe sich durch Bezug von Biogas und Ökostrom weiter steigern.

Der Vorteil des hybriden Systems mit Erdwärmepumpe und KWK-Modul ist die Koppelung des Strom- und Wärmemarktes und die damit verbundene zusätzliche Flexibilitätsoption für den Strommarkt (Strom verbrauchen oder produzieren). Ein Zusammenspiel dieser Wärmeerzeuger befähigt das Nahwärmesystem, neben Umweltschonung und Wirtschaftlichkeit auch die Netzdienlichkeit in eine umfassende Betriebsoptimierung mit einzubeziehen. Das aus Erzeugern mit unterschiedlichen Energiequellen (Sonne, Graustrom, Ökostrom, selbst produzierter Strom, Erdgas, Biogas) bestehende Nahwärmesystem kann flexibel auf sich verändernde energiewirtschaftliche Rahmenbedingungen, z.B. Strommarktsituationen (hohe, niedrige, negative Strompreise), Netzbedingungen (hohe, niedrige Auslastung des Stromnetzes) und andere Randbedingungen (Sonneneinstrahlung, Außentemperaturen, Wärmelast) reagieren. Neben einer direkten Einspeisung der Wärmeerzeuger in das Nahwärmenetz besteht auch die Möglichkeit eines multivariaten Energietransfers zwischen den Erzeugern. So hat die Wärmepumpe Zugriff auf den Solarwärmespeicher als Wärmequelle und es ist eine direkte Nutzung des in der

KWK-Anlage produzierten Stroms zum Antrieb der Wärmepumpe oder des Heizstabs möglich. Ein entsprechend komplexes Wärmeversorgungssystem benötigt zur Hebung der maximalen Kostenminderungs-, CO<sub>2</sub>-Minderungs- und Netzdienstlichkeits-Potentiale ein geeignetes Regel- und Steuerungssystem. Die Regel- und Steuerung soll so ausgestaltet werden, dass mittels Messwerten aus der Anlage und Kurzzeitprognosewerten für externe Größen wie Wetter, Strom- und Gaspreis und Wärmelast jederzeit die kosten- und / oder energieeffizienteste Betriebsstrategie gefahren wird. Dafür wird das Nahwärmesystem mit entsprechender Mess- und Steuerungstechnik ausgestattet, wodurch es flexibel auf unterschiedliche Markt-, Netz- und Bedarfsanforderungen reagieren kann.

Da die Randbedingungen während der Lebensdauer des Systems kontinuierlichen Änderungen ausgesetzt sind, soll die Regelung selbstlernend sein und gleichzeitig über ein Überwachungs- und Priorisierungssystem für den Betreiber verfügen. Selbstlernende Algorithmen analysieren beispielsweise, zu welchen Zeiten typischerweise an den einzelnen Tagen der Woche Wärme benötigt wird. Das System erkennt die Gewohnheiten und hebt bei Bedarf z.B. die Netztemperaturen an. Es greift auf Wetterprognosen zu und kann dadurch die solare Wärmeproduktion stundengenau vorhersagen. Es ermöglicht somit genaue Vorhersagen des Gas- und Stromverbrauchs für kurz- und mittelfristige Zeiträume und befähigt so den Betreiber, beim Day-Ahead- oder sogar Intraday-Handel erfolgreich teilzunehmen. Selbstlernende Systeme können besonders gut durch nicht parametrische Metamodelle wie künstliche neuronale Netze abgebildet werden. Diese haben bei der Auswertung einen deutlichen Geschwindigkeitsvorteil gegenüber den sonst eingesetzten detaillierten Systemsimulationen oder anderen Lösungsansätzen. Die Schnelligkeit künstlicher neuronaler Netzwerke begünstigt auch den Einsatz von sonst rechenintensiven Optimierungsalgorithmen zur Ermittlung der optimalen Regelungs- und Einsatzparameter unter Berücksichtigung von Prognosen relevanter Randbedingungen mehrere Stunden in die Zukunft.

## **2. Eine Wärmezentrale entsteht**

Die Planung der Wärmebereitstellung basiert auf einer von der Hochschule Düsseldorf im Vorfeld durchgeführten Studie (Adam, 2018) zur optimalen Ausgestaltung für multivariate Wärmebereitstellung. Diese erbrachte als vielversprechende Konfiguration für die Zukunft die umgesetzte Kombination aus Solarthermie, Wärmepumpe, KWK-Modul und Spitzenlastheizgerät. Gegenüber der Planung wurde zusätzlich zur Wärmepumpe ein elektrischer Direktheizer mit 30 kW und eine 10 kW<sub>p</sub> Photovoltaikanlage mit Batteriespeicher installiert. Bis auf das Spitzenlastheizgerät sind alle Wärmeerzeuger und das Wärmenetz an einen zentralen 50 m<sup>3</sup> fassenden Heizwasserspeicher (siehe Abb. 1) über Ladelanzen angeschlossen. Das Solarthermiefeld besteht aus Röhrenkollektoren mit einer Bruttokollektorfläche von 211 m<sup>2</sup>. Neben dem Solarthermiefeld wurde das Erdsondenfeld mit sechs auf 99 m abgeteuften Sonden platziert. Dank des hohen Grundwasserspiegels in bereits 2 m Tiefe und einer nennenswerten Grundwasserströmung ist eine hohe jährliche Entzugsleistung zu erwarten. Gleichwohl dient das Erdsondenfeld im Sommer zur Kühlung der Solarthermie, sollte die Solarwärme einmal nicht vom Speicher aufgenommen werden können. So kann einerseits die Technik im Solarteil vor einer hohen Temperaturbelastung bewahrt und gleichzeitig die Erdsonden im kleinen Maßstab durch Solarwärme regeneriert werden. Der primäre Einsatzzweck des Erdsondenfelds aber ist der als Wärmequelle für die Wärmepumpe mit einer Heizleistung von 50 kW<sub>th</sub>. Neben den erneuerbaren Wärmeerzeugern sind Gas-KWK-Module mit insgesamt 150 kW<sub>el</sub> respektive 267 kW<sub>th</sub> (im Endausbau) und ein Spitzenlastheizgerät mit 725 kW<sub>th</sub> zur Deckung des Spitzenbedarfs installiert.

Anfang 2019 begann die Erschließung des Baugebiets und die Errichtung der Heizzentrale (siehe Abb. 2) im Kempener Stadtteil St. Hubert.



Abb. 1: Einbringung des Wärmespeichers



Abb. 2: Ansicht Heizzentrale mit Solarthermie-, Erdsonden- und Photovoltaikfeld

Im Endausbau wird das Nahwärmenetz 130 Wohneinheiten versorgen, bestehend aus überwiegend Einfamilienhäusern. Mit 55 °C im Netzvorlauf und 35 °C im Netzurücklauf handelt es sich bei diesem Netz um Low Temperature District Heating (LTDH) (Schmidt, 2018) bzw. um ein Wärmenetz der vierten Generation (4GDH) (Lund et al., 2014). Entsprechend erfolgt die Warmwasserbereitung bei den Kunden verbrauchsnahe über Durchflusssysteme in Form von Haus- bzw. Wohnungsstationen in den Mehrfamilienhäusern. Eine zentrale Warmwasserbereitung mit Zirkulation, wie sie in Mehrfamilienhäusern oft gebräuchlich ist, ist in einem solchen, auf Energieeffizienz und niedrige Wärmeverluste konzipierten Netz nicht möglich.

### 3. Das Regel- und Steuerungssystem

Eine derartig flexible Heizzentrale benötigt zur Hebung der oben genannten Potentiale ein ebenso flexibles und intelligentes Regel- und Steuerungssystem. Dabei besteht die Aufgabe darin, aus einer Vielzahl an möglichen Fahrweisen die optimale Betriebsführung für das kommende Zeitintervall (z.B. 1h) zu ermitteln. Der optimale Betrieb hängt dabei von derzeitigen und zukünftigen Randbedingungen, wie dem Wetter, den Temperaturen im Speicher, den Marktpreisen etc., ab. Für einen Teil der Randbedingungen wird das Regel- und Steuerungssystem die Prognosewerte

automatisch bei Drittanbietern abrufen oder direkt selbst erstellen. Andere für die Optimierung notwendige Werte werden direkt in der Heizzentrale gemessen.

Eine Möglichkeit, solch komplexe Systeme zu optimieren, ist im ersten Schritt die Aufstellung eines Gleichungssystems, welches die Heizzentrale in ihrer Funktion abbildet. Die Betriebsoptimierung geschieht dann oft über eine gemischt-ganzzahlige Optimierung (Stange, 2018; Kallrath, 2002, Urbanucci, 2018). Vorteil dieses Ansatzes ist dessen Schnelligkeit bei kurzen Zeithorizonten, Nachteilig ist dessen fehlende Flexibilität und die stark ansteigende Rechendauer mit länger werdenden Zeitintervallen und komplexer werdendem Gleichungssystem. Das für die gemischt-ganzzahlige Optimierung notwendige Gleichungssystem ist statisch und bildet die Heizzentrale mit dessen Wärmeerzeugern oft nur ideal ab. Selbst wenn anfangs das ideale Modell die Wärmeerzeugung noch mit geringem Fehler abbilden kann, sind im Laufe der Lebensdauer Änderungen im Betriebsverhalten zu erwarten, die zur fehlerhaften Lokalisation des Betriebsoptimums führen können. Künstliche neuronale Netzwerke (KNN) (Förderer et al., 2018) als Approximationsmodell sind hier im Vorteil. Durch periodisches Training mit Daten aus dem laufenden Betrieb kann das Approximationsmodell permanent auf das tatsächliche Verhalten der Heizzentrale angepasst werden und gewährleistet so eine hohe Güte der ermittelten Optima während der gesamten Nutzungsdauer.

Im Gegensatz zu Bestandsanlagen liegen bei neuerrichteten Anlage keine Daten vor, mit denen ein solches KNN trainiert werden könnte. Deshalb wird für ein Initialtraining ein Systemmodell der Heizzentrale unter MATLAB/Simulink/CARNOT (MathWorks, 2019; SIJ, 2019) erstellt, welches die Realität möglichst ideal abbildet und als Datengrundlage dient. Mit den Daten, die während des Betriebs anfallen, finden dann die weiteren Trainings statt.

### **3.1 Systemmodell**

Das unter MATLAB/Simulink/CARNOT (MathWorks, 2019; SIJ, 2019) erstellte Systemmodell der Heizzentrale ist schematisch in Abb. 3 dargestellt. Die Abbildung stellt ein Teilmodell der gesamten Heizzentrale dar, mit dessen Hilfe erste KNN zur Prognose von Speichertemperaturen trainiert wurden, um deren Performanz zu testen. Elemente der Heizzentrale sind als Blöcke dargestellt. Mittig der Wärmespeicher, links davon KWK-Modul und Kessel, unten das Solarthermiefeld, rechts davon die Wärmepumpe mit Erdsondenfeld und oben die Netzpumpen mit Regelstrecke für Netzvorlauftemperatur inkl. generischer Wärmelast.

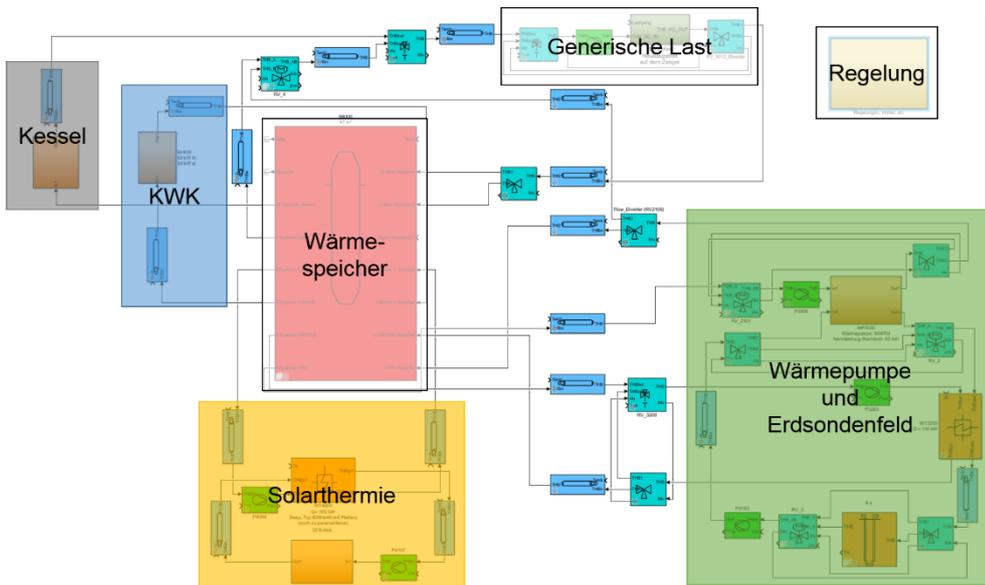


Abb. 3: Systemmodell der Heizzentrale unter MATLAB/Simulink/CARNOT mit Hervorhebungen einzelner Anlagenteile.

Die generische Wärmelast des Wärmenetzes enthält den Heiz- und Warmwasserwärmebedarf der Kunden, erhöht um Netzverluste. Der Heizwärmebedarf entspricht Gebäuden im Neubaustandard, der Warmwasserwärmebedarf wurde mit der Software DHWcalc (Jordan, 2005) für das komplette Wärmenetz ermittelt. Der jährliche Gesamtwärmebedarf beträgt rund 1 GWh/a womit das Versorgungsgebiet eine Wärmebedarfsdichte von 1,15 MWh/(m<sup>2</sup>a) aufweist, siehe hierzu Abb. 4.

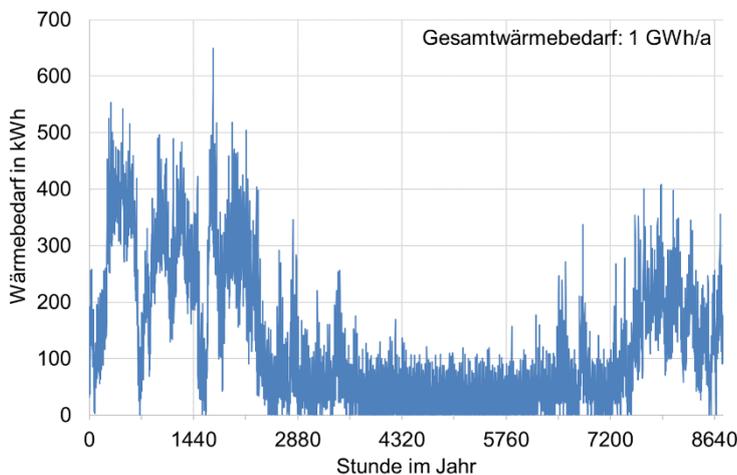


Abb. 4: Prognostizierter stündlich aufgelöster Wärmebedarf des Netzes (Heiz-, Warmwasserwärmebedarf und Netzverluste) in der finalen Ausbaustufe mit 130 Wohneinheiten

Die Regel- und Steuerung der simulierten Anlage erfolgt zunächst wärmegeführt. Analog zu EE-Stromerzeugern im Strommarkt hat die Solarthermie einen Einspeisevorrang vor allen anderen Wärmeerzeugern. Ist der Energieeintrag der Solarthermie nicht ausreichend bzw. reicht die Wärme aus dem Speicher nicht aus, startet zunächst das KWK-Modul und falls notwendig danach die Wärmepumpe. In Spitzenzeiten übernimmt der Spitzenlastkessel den Fehlbetrag. Ein Betrieb der elektrischen Direktheizung ist in diesem ersten Regelkonzept nicht vorgesehen. Der erwartete Wärmebedarf und die simulierte Erzeugung sind in Abb. 5 als geordnete Jahresdauerlinie abgebildet.

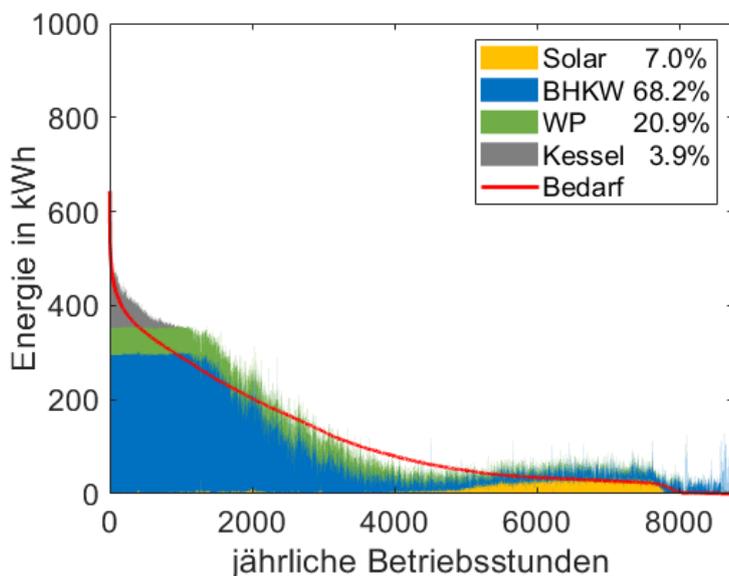


Abb. 5: Geordnete Jahresdauerlinie von Wärmebedarf und -erzeugung im ersten einfachen Regelungsansatz

Eine Jahressimulation mit Wetterdaten vom nahegelegenen Standort Krefeld lieferten anschließend die Trainings- und Vergleichsdaten für ein erstes Training der KNN.

### 3.2 Erstes Training

Mit Hilfe des künstlichen neuronalen Netzwerkes soll in Abhängigkeit des thermischen Zustands des Systems (d.h. der Beladung des Speichers), diverser Randbedingungen sowie der Regelgrößen eine Prognose über ökologische und ökonomische Zielgrößen in festgelegten Zeitintervallen getroffen werden. Aufgrund der Trägheit des Systems und der schwankenden Randbedingungen muss eine Betriebsoptimierung in diesen Zeitintervallen auf Basis mehrerer Zeitschritte erfolgen. Dies führt letztlich dazu, dass neben den ökologischen und ökonomischen Zielgrößen auch der thermische Zustand des Systems sowie die Randbedingungen prognostiziert werden müssen. Eine vereinfachte Darstellung der Prognose mit einem solchen System, bestehend aus einer Vielzahl an KNNs, ist in Abb. 6 gezeigt:

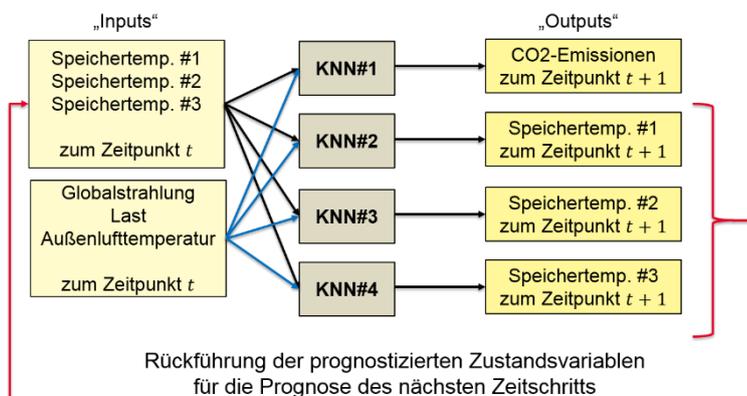


Abb. 6: Schematische Prognose der CO<sub>2</sub>-Emissionen auf Basis prognostizierter Speichertemperaturen sowie extern prognostizierter Randbedingungen (bspw. die Last im nächsten Zeitschritt) anhand von künstlichen neuronalen Netzwerken (KNN). Regelgrößen müssen ebenfalls für die Prognose berücksichtigt werden, sind hier aber nicht dargestellt.

Das Training der KNNs erfolgt derzeit in MATLAB mit Hilfe der *Neural Network Toolbox* (Version 11.1). Als Trainingsalgorithmus wird Bayesian Regularisation verwendet, was eine Regulisierung der Netzwerk-Hyperparameter während des Trainings durchführt und somit eine größere Menge an Daten für das Training zulässt. Die Netzwerk-Struktur wird über einen heuristischen Suchalgorithmus bestimmt. Abb. 7 zeigt erste qualitative Ergebnisse der Prognose der Speichertemperaturen, wobei ein Prognoseintervall von jeweils fünf Stunden verwendet wurde. Ein Prognoseintervall besteht dabei aus fünf aufeinander folgende Prognosen (Zeitschritte), siehe Abb. 6, wovon die erste Prognose Speichertemperaturen aus der Simulation als Startwerte erhält und die darauf folgenden Prognosen als Startwert die Prognosewerte des jeweils vorangegangenen Zeitschritts nutzen. Zum Vergleich: Die Zeitschritte in der Vergleichssimulation unter MATLAB/Simulink sind deutlich kürzer reichen bis in den Sekundenbereich.

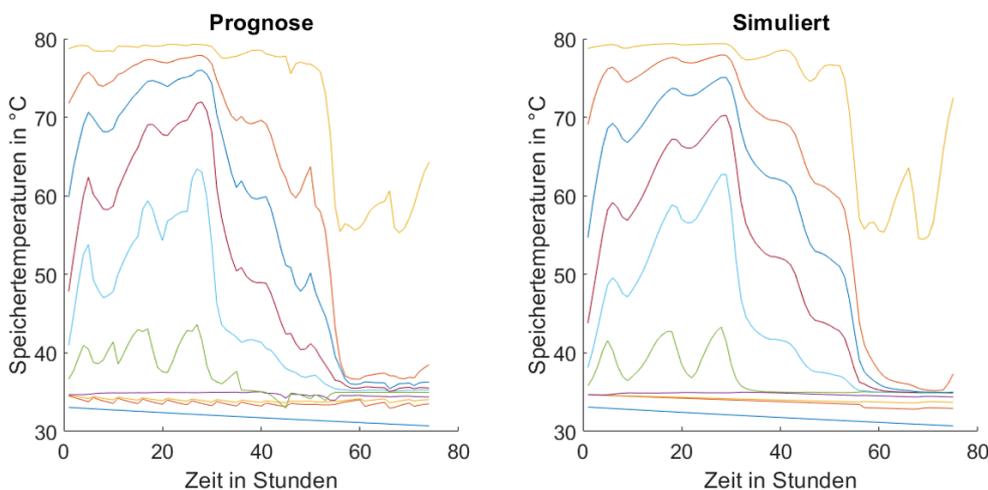


Abb. 7: Simulation (rechts) und Prognose (links) der Speichertemperaturen. Die Prognose erfolgte mit einem Zeitintervall von jeweils fünf Stunden d.h. nach jeweils fünf Stunden erfolgte eine Aktualisierung der Inputs.

Die ersten Ergebnisse deuten einen erfolgsversprechenden Ansatz an. Weitere Anpassungen des Algorithmus werden derzeit im Projekt umgesetzt.

## 5. Ausblick

Die Finalisierung des Systemmodells und die Generierung der ersten vollumfänglichen Trainingsdaten stehen derzeit im Fokus der Arbeiten. Anschließend erfolgen vergleichende Analysen der Performanz von in Frage kommenden Netztopologien und Trainingsmethoden der KNN zur Abbildung des Betriebsverhaltens der Heizzentrale. Parallel wird das Monitoring von klassischen im Vergleich zu einer innovativen Hausstation vorbereitet.

## Quellenangaben

ADAM, M. et al. (2018). Multi-Objective Optimization of a District Heating Networks Energy Supply Systems Structure and Dimension, Proceedings 5th Solar District Heating Conference

SCHMIDT, D. (2018). Low Temperature District Heating for Future Energy Systems, *Energy Procedia*, Volume 149, 595-604, <https://doi.org/10.1016/j.egypro.2018.08.224>.

LUND, H. et al. (2014). 4th Generation District Heating (4GDH): Integration smart thermal grids into future sustainable energy system, *Energy*, Volume 68, 1-11, <https://doi.org/10.1016/j.energy.2014.02.089>.

STANGE, P. (2018). Operational optimization of energy systems, 25 years – established and promising use cases, *Energy Procedia*, Volume 149, 15-24, <https://doi.org/10.1016/j.egypro.2018.08.165>.

KALLRATH, J. (2013). Gemischt-Ganzzahlige Optimierung. Modellierung in der Praxis, *Springer Vieweg*, Wiesbaden, 10.1007/978-3-658-00690-7.

URBANUCCI, L. (2018). Limits and potentials of Mixed Integer Linear Programming methods for optimization of polygeneration energy systems, *Energy Procedia*, Volume 148, 1199-1205, <https://doi.org/10.1016/j.egypro.2018.08.021>.

FÖRDERER, K. (2018). Modeling flexibility using artificial neural networks, *Energy Inform*, Volume 1, 21, <https://doi.org/10.1186/s42162-018-0024-4>.

MathWorks (2019). Simulation an Model-Based Design SIMULINK, <https://de.mathworks.com/products/simulink.html>, Letzter Zugriff am 27. September 2019.

JORDAN, U. & VAJEN, K. (2005). DHWcalc: Programm to generate domestic hot water profiles with statistical means for user defined conditions, *Proc. ISES Solar World Congress*, <https://www.uni-kassel.de/>.

Solar-Institut Juelich (SIJ) (2019). CARNOT Toolbox for calculation and simulation of thermal components of HVAC systems under MATLAB SIMULINK, <https://www.fh-aachen.de/forschung/solar-institut-juelich/carnot/>, Letzter Zugriff am 27. September 2019.

HUSMEIER, D. (1999). Neural Networks for Conditional Probability Estimation, *Springer*, London, <https://doi.org/10.1007/978-1-4471-0847-4>.

ZEISBERGER, J. (2017). Beitrag zur energieeffizienten Trinkwassererwärmung: Messtechnische Untersuchungen zur Bewertung und Optimierung von Trinkwassererwärmungssystemen, Dissertation, TU München, <https://mediatum.ub.tum.de/doc/1356343/1356343.pdf>, Letzter Zugriff 27. September 2019.

MERCKER, O. & Arnold, O. (2017). Ansätze zur Reduktion der konventionell erzeugten Wärmeverteilverluste in solar unterstützten Mehrfamilienhäusern, *Abschlussbericht*, ISFH, <https://isfh.de>, Letzter Zugriff 27. September 2019

SULZER, M. & Hangartner, D. (2014). Kalte Fernwärme (Anergienetze), Hochschule Luzern.

ZVINGILAITE, E. et al. (2012). Low Temperature District Heating Consumer Unit with Micro Heat Pump for Domestic Hot Water Preparation, In *Proceedings of the 13th International Symposium on District Heating and Cooling*, 136-143.

DITTMANN, A. (2007). Senkung der Zirkulationsverluste in zentralen Trinkwassererwärmungsanlagen, AiF-Forschungsbericht (Report Nr. AiF14244BR).

ZIES - Zentrum für innovative Energiesysteme, Münsterstraße 156, 40476 Düsseldorf  
[mario.adam@hs-duesseldorf.de](mailto:mario.adam@hs-duesseldorf.de)