

# Energieforschungsprogramm

## Publizierbarer Endbericht

**Programmsteuerung:**

Klima- und Energiefonds

**Programmabwicklung:**

Österreichische Forschungsförderungsgesellschaft mbH (FFG)

Endbericht

erstellt am

19/09/2022

**Projekttitlel:**

**Künstliche Intelligenz in der Wärmetechnik**

Projektnummer: 881172

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

|                                    |  |
|------------------------------------|--|
| Ausschreibung                      | 06. Ausschreibung Energieforschungsprogramm                        |
| Projektstart                       | 01/04/2021   |
| Projektende                        | 31/09/2022   |
| Gesamtprojektdauer<br>(in Monaten) | 18 Monate  |
| ProjektnehmerIn<br>(Institution)   | Technische Universität Graz, Institut für Wärmetechnik             |
| AnsprechpartnerIn                  | Ass.Prof. Dr. Rene Prieler   |
| Postadresse                        | Inffeldgasse 25b, 8010 Graz  |
| Telefon                            | 0043 316 873 7810  |
| Fax                                | 0043 316 873 7305  |
| E-mail                             | <a href="mailto:rene.prieler@tugraz.at">rene.prieler@tugraz.at</a> |
| Website                            | <a href="http://www.iwt.tugraz.at">www.iwt.tugraz.at</a>           |

## Künstliche Intelligenz in der Wärmetechnik

**AutorInnen:**

Institut für Wärmetechnik, Technische Universität Graz

Rene Prieler

Andreas Heinz

Institut für Regelungs- und Automatisierungstechnik, Technische Universität Graz

Alberto Ismael Castillo Lopez

Martin Steinberger

Martin Horn

Institut für Softwaretechnologie, Technische Universität Graz

Lea Zinkanell

Gerald Steinbauer

## 1 Inhaltsverzeichnis

|       |   |    |
|-------|---|----|
| 1     | Inhaltsverzeichnis  | 4  |
| 2     | Einleitung  | 5  |
| 2.1   | Hintergrund   | 5  |
| 2.2   | Projektziele und Methodik   | 5  |
| 3     | Inhaltliche Darstellung   | 7  |
| 3.1   | Literaturrecherche  | 7  |
| 3.2   | Beschreibung der betrachteten wärmetechnischen Anwendung                                | 9  |
| 3.3   | Systemaufteilung in Subsysteme  | 12 |
| 3.3.1 | Beschreibung der Subsysteme   | 13 |
| 3.4   | KI-basierte Modelle für den Solarkreislauf, das Wärmeabgabesystem und den Wärmespeicher | 15 |
| 3.4.1 | LSTM  | 15 |
| 3.4.2 | CNN   | 15 |
| 3.4.3 | Autoregressives Modell / Ansatz der externen Dynamik                                    | 15 |
| 3.4.4 | Neuro-Fuzzy Modell (NFM)  | 16 |
| 3.4.5 | Lineare Regression  | 17 |
| 3.4.6 | Bewertungsgrößen für die Performance der Modelle  | 18 |
| 3.5   | Datenaufbereitung und Training  | 18 |
| 3.6   | Regelungsansatz für eine modellprädiktive Regelung (MPC) des betrachteten Systems       | 21 |
| 4     | Ergebnisse und Schlussfolgerungen   | 26 |
| 4.1   | KI-basierte Modellierungs-Ansätze und deren Performance                                 | 26 |
| 4.1.1 | CNN   | 26 |
| 4.1.2 | LSTM  | 29 |
| 4.1.3 | Autoregressives Modell  | 32 |
| 4.1.4 | Monatsweise Modelle   | 32 |
| 4.1.5 | Lineare Regression  | 32 |
| 4.1.6 | NFM-LoLiMoT Modell  | 35 |
| 4.2   | Modellprädiktive Regelung mit KI-basierten Modellen                                     | 38 |
| 5     | Ausblick und Empfehlungen   | 41 |
| 6     | Literaturverzeichnis  | 42 |
| 7     | Anhang: Tabelle mit Ergebnissen der Literaturrecherche                                  | 44 |
| 8     | Kontaktdaten  | 65 |

## 2 Einleitung

### 2.1 Hintergrund

Das Ziel des Projekts KlinWT ist die Sondierung der technischen Durchführbarkeit und Sinnhaftigkeit des Einsatzes von aktuellen Methoden der Künstlichen Intelligenz (KI) in der Modellierung, der Regelung und dem Monitoring von wärmetechnischen Anwendungen. Für eine konkrete Anwendung und ausgewählte, typische wärmetechnische Problemstellungen erfolgt eine Bewertung des Potentials der eingesetzten KI-Methoden hinsichtlich Arbeits- und Zeitersparnis, Energieeinsparung und Verbesserung der Betriebssicherheit.

Mehr als die Hälfte des gesamten Endenergieverbrauchs fällt in Österreich in Form von Wärme (Raumheizung und Klimaanlage, Dampferzeugung, Industrieöfen) an. Um die aufgewendete Energie in den erwähnten Bereichen bestmöglich zu nutzen, müssen sowohl die Einzelprozesse (z.B. Feuerungen, Wärmepumpen) als auch die Gesamtsysteme eine möglichst hohe Effizienz aufweisen. Die Regelung und Überwachung der vorhandenen technischen Prozesse nimmt dabei eine wichtige Rolle ein, sowohl was die Energieeffizienz als auch was die Betriebssicherheit angeht.

Derzeit eingesetzte Steuerungs- und Regelungskonzepte basieren oft auf Erfahrungswerten, zielen jedoch kaum auf eine möglichst hohe Energieeffizienz ab. Regelungsziele sind oft starr ausgeführt und zielen eher auf die Stabilisierung des Prozesses ab. Eine Optimierung der Regelung wird bei kleinen Anlagen kaum durchgeführt, solange keine Störungen oder Komfortverletzungen auftreten. Bei Industrieprozessen ist es oft schwierig überhaupt einen Optimierungsprozess in der laufenden Produktion einzuleiten, weil das primäre Augenmerk eher auf die Produktqualität als die energetische Effizienz gerichtet wird. Bisher entwickelte und auch bereits eingesetzte Modellprädiktive Regelungsansätze (MPC) versprechen zwar signifikante Energieeinsparungen, die Erstellung der notwendigen Modelle erfordert jedoch Expertenwissen und ist zeitaufwändig, was als Hemmnis für einen breiteren Einsatz wirkt.

Auf Grundlage der rasant steigenden Leistungsfähigkeit digitaler Systeme und Methoden aus dem Bereich der Künstlichen Intelligenz (KI) zeichnen sich jedoch neue Möglichkeiten ab, sowohl die Effizienz über intelligente regelungstechnische Maßnahmen als auch die Betriebssicherheit über innovative Diagnosemethoden zu verbessern.

### 2.2 Projektziele und Methodik

Im vorliegenden Sondierungs-Projekt wurde eine Listung, Evaluierung, und Klassifizierung unterschiedlicher Problemstellungen in verschiedenen wärmetechnischen Anwendungen durchgeführt. Derzeit übliche Regelungs- und Monitoring-Strategien und Modellierungsansätze für die definierten Problemstellungen wurden dokumentiert. Anhand einer Literaturrecherche wurde der Stand der Forschung und Entwicklung im Bereich innovativer Regelungs-, Monitorings- und Modellierungs-Methoden für die Anwendung von KI in den betrachteten wärmetechnischen Anwendungen ermittelt.

Im Projekt wurde die Möglichkeit, das Verhalten von Anlagen bzw. einzelner Anlagenteile anhand von datenbasierten Modellen abzubilden, untersucht. Dazu wurden für die konkrete Anwendung eines solaren Kombisystems für Heizung und Warmwasserbereitung verschiedene Modellierungs-Verfahren basierend

auf KI-Methoden für einzelne Anlagenteile erprobt. Anhand von System-Simulationen wurde der Einsatz einer modellprädiktiven Regelung (MPC), die statt physikalischen Modellen des Systems rein Datenbasierte Modelle verwendet, erprobt. Die mögliche Energieeinsparung durch die MPC-Regelung im Vergleich zu einer konventionellen Regelung wurde bewertet.

## 3 Inhaltliche Darstellung

### 3.1 Literaturrecherche

Als erster Schritt im Projekt wurde eine Literaturrecherche über bestehende Arbeiten zu Anwendungen von künstlicher Intelligenz in der Wärmetechnik durchgeführt. Dabei wurden sowohl Veröffentlichungen zu Gebäude-Anwendungen (Heizung und Kühlung) und in industriellen Prozessen betrachtet. Künstliche Intelligenz kann eingesetzt werden, um Prozesse wie Klima- und Lüftungsanlagen zu beschreiben, zu steuern und zu verbessern. Außerdem können KI-Tools zur intelligenten Fehlerdiagnose eingesetzt werden.

Die Literaturrecherche wurde über Google Scholar und ScienceDirect durchgeführt, mit einer groben Kategorisierung in Gebäudeanwendungen und industrielle Prozesse. In Abbildung 1 sind die Suchbegriffe dargestellt, die jeweils in den Suchmaschinen verwendet wurden. Die Größe der Kreise zeigt an, wie viele relevante Artikel jeweils gefunden werden konnten.

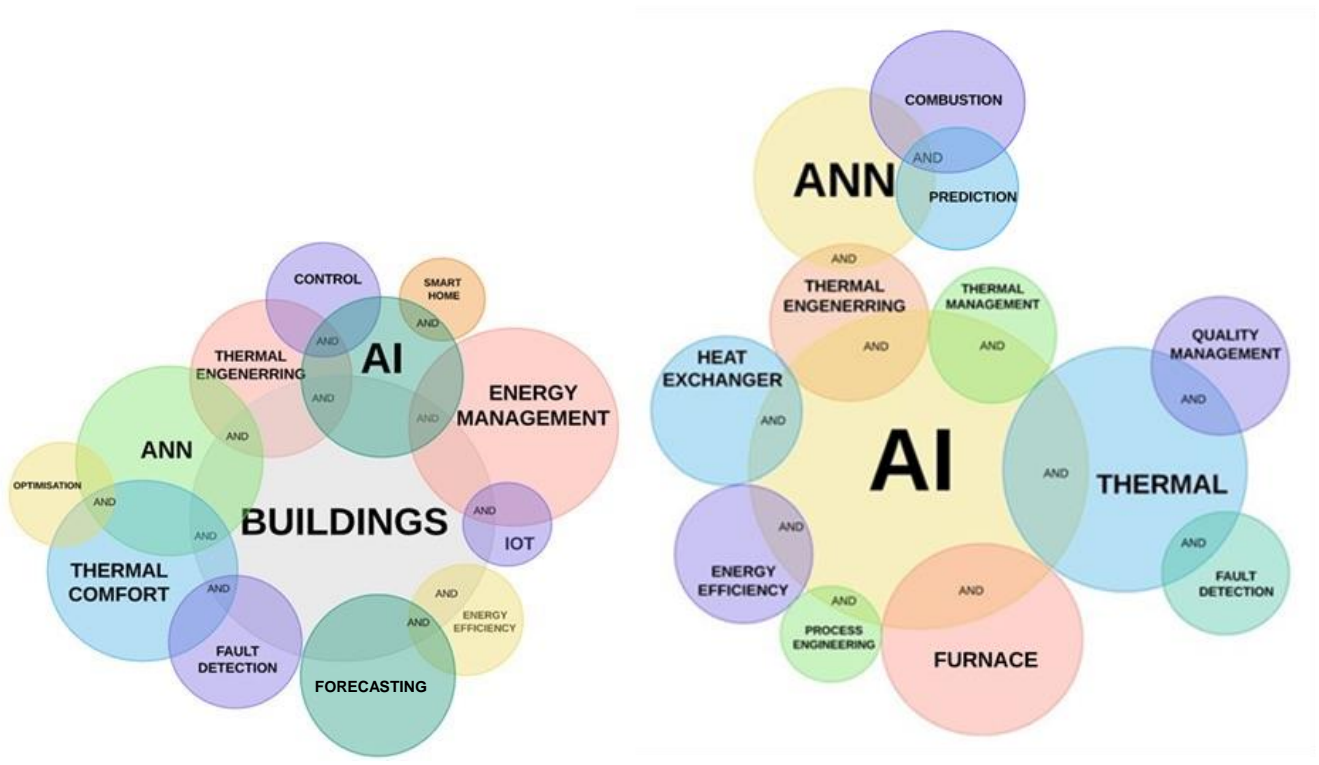


Abbildung 1: Suchbegriffe für die Literaturrecherche zum Thema Gebäude (links) und Industrielle Prozesse (rechts)

Um einen groben Überblick zu erhalten, wurden zunächst Übersichtsartikel (review papers) über verschiedene Anwendungen von künstlicher Intelligenz in der Wärmetechnik gesucht. Es wurden grundsätzlich mehr Studien gefunden, die Anwendungen in Gebäuden beschreiben, wobei es auch eine große Anzahl von Arbeiten aus den Jahren 1990-2000 gibt. Die Technologie hat sich aber seither erheblich weiterentwickelt, daher wurde die Recherche vor allem auf Arbeiten nach dem Jahr 2010 konzentriert. Als ein Ergebnis der Recherche wurden alle gefundenen Arbeiten in einer Tabelle zusammengefasst,

kategorisiert und die wichtigsten Ergebnisse kurz dargestellt. Die Tabelle ist im Anhang dieses Berichts enthalten.

Obwohl künstliche Intelligenz in den letzten Jahren durchaus im Trend lag - insbesondere bei IT-Anwendungen und Big Data etc. - konnten auch für den Bereich der Wärmetechnik einige ältere Studien aus den frühen 2000er Jahren gefunden werden. Die zunehmende Anzahl von Veröffentlichungen zum Thema KI in der Wärmetechnik aus den späten 2010er und frühen 2020er Jahren deutet auf ein wachsendes Interesse hin, dieses Werkzeug in thermischen Anwendungen einzusetzen.

Die prominentesten KI-Tools in den gefundenen Veröffentlichungen waren künstliche neuronale Netze in verschiedenen Formen. In geringerem Umfang wurde auch der maschinelle Lernalgorithmus Random Forest erwähnt. Es wurde auch festgestellt, dass es eine vergleichsweise sehr hohe Anzahl von Veröffentlichungen aus dem asiatischen Raum gibt.

Insgesamt lässt sich sagen, dass eine Hauptanwendung der KI für wärmetechnische Zwecke die Modellierung ansonsten schwer beschreibbarer Prozesse ist. Dies gilt insbesondere für den Bereich der industriellen Anwendungen, die einen der Schwerpunkte dieser Literaturrecherche bildete. Hier wird KI häufig eingesetzt, um das instationäre Verhalten von Systemen vorherzusagen, was mit auf der Physik basierenden, numerischen Ansätzen (z.B. CFD) schwieriger zu erreichen ist.

Darüber hinaus gibt es auch einige wenige Studien, die KI-Werkzeuge zur energetischen Optimierung von wärmetechnischen Prozessen und Fehlererkennung einsetzen. Nur sehr wenige Studien befassen sich mit neuen Regelungskonzepten für industrielle Prozesse, und wenn, dann handelt es sich häufig um theoretische Studien, die meist über Simulationen und nicht in realen Prozessen getestet wurden. Dies könnte eine Folge der Tatsache sein, dass Eingriffe im Produktionsprozess (z. B. in Stahlwerken) mit einem erheblichen Risiko verbunden sind, weshalb Betreiber bei der Implementierung neuer Regelungskonzepte zurückhaltend agieren.

Im Gegensatz dazu wurden einige Arbeiten gefunden, in denen KI in der Gebäudetechnik schon aktiv für Regelungszwecke eingesetzt wird. Dies reicht von der Regelung des thermischen Komforts bis zu Energiemanagementsystemen für Gebäude. Weitere Anwendungen in der Literatur sind Prozessmodellierung, Fehlererkennungs- und Diagnosesysteme und Effizienzoptimierung.

## 3.2 Beschreibung der betrachteten wärmetechnischen Anwendung

Im Projekt wurde ein solarthermisches Kombisystem für Raumheizung und Warmwasserbereitung in einem Einfamilienhaus als wärmetechnisches Anwendungsszenario verwendet, um die Anwendung verschiedener KI-Techniken zu testen. Ein detailliertes Simulationsmodell wurde in TRNSYS auf der Grundlage eines Systems erstellt, das in einem früheren Projekt verwendet wurde (Heimrath und Haller, 2007). Die Analysen im Projekt wurden auf der Grundlage der mit diesem Modell erzeugten Simulationsdaten durchgeführt.

### Gebäude und Klima

Das verwendete Gebäudemodell basiert auf der Gebäudegeometrie, die im IEA SHC Task 32 (Heimrath und Haller, 2007) definiert wurde und in Abbildung 2 dargestellt ist. Es handelt sich um ein freistehendes, zweigeschossiges Einfamilienhaus. Die Nutzfläche eines Geschosses, einschließlich der Flächen der Innenwände und der Erschließungsflächen, beträgt 70 m<sup>2</sup>. Die verglaste Fläche an der Südfassade beträgt 25 % der Fassadenfläche, 10 % an der Ost- und Westfassade und 6 % an der Nordfassade. Die beiden Geschosse werden als zwei getrennte thermische Zonen simuliert. Für die Arbeiten im Projekt wurde die in (Bertsch et al., 2013) beschriebene Variante "SFH45" des Gebäudes verwendet, die bei dem verwendeten Klima und einer eingestellten Raumtemperatur von 22 °C einen Heizwärmebedarf von 7800 kWh/a hat. Für das Wärmeabgabesystem (HES) wurde eine Fußbodenheizung angenommen, die vereinfacht mit dem dynamischen Heizkörpermodell Typ 362 von Holst (1996) modelliert wurde. Um das Verhalten einer Fußbodenheizung zu simulieren, wurde die Parametrisierung hinsichtlich des Heizkörperexponenten (Konvektion und Strahlung = 1,1) und der Wärmekapazität (160 kJ/kg pro m<sup>2</sup> Bodenfläche) entsprechend gewählt.




Abbildung 2: Ansicht des im Projekt verwendeten Einfamilienhauses (Bertsch et al., 2013)

Das angenommene Klima ist ein durchschnittlicher Klimadatensatz für die Stadt Graz, der mit der Software Meteororm (Meteotest, 2020) erstellt wurde. Die Jahressumme der Globalstrahlung auf die Horizontale

beträgt 1143 kWh/(m²a), die Jahresmitteltemperatur der Luft beträgt 8,4 °C mit Heizgradtagen  $HGT_{20/12}$  von 3738 Kd/a.

## Heizungssystem

Das solare Kombisystem besteht aus einem thermischen Energiespeicher (TES), dem Solarkreislauf (SCL), einem Heizkessel als konventionelle Nachheizung (AH), einem Frischwassermodul für die Warmwasserbereitung und dem Heizungskreislauf mit dem Wärmeabgabesystem (HES) im Gebäude. Abbildung 3 zeigt eine schematische Darstellung des Systems.

Der Kollektorkreislauf ist an 20 m² thermische Solarkollektoren (Flachkollektoren) angeschlossen, die auf dem Dach mit einer Neigung von 45° und nach Süden ausgerichtet montiert sind. Der Kollektorkreislauf ist mit einem Wasser-Glykol-Gemisch gefüllt und daher über einen Plattenwärmetauscher mit dem TES verbunden. Der TES kann durch Umschalten eines Dreiwegeventils in zwei verschiedenen Höhen durch den Solarkreislauf beladen werden. Der TES hat ein Wasser-Volumen von 1000 Litern und einen Wärmeverlustkoeffizienten von 2,36 W/K.

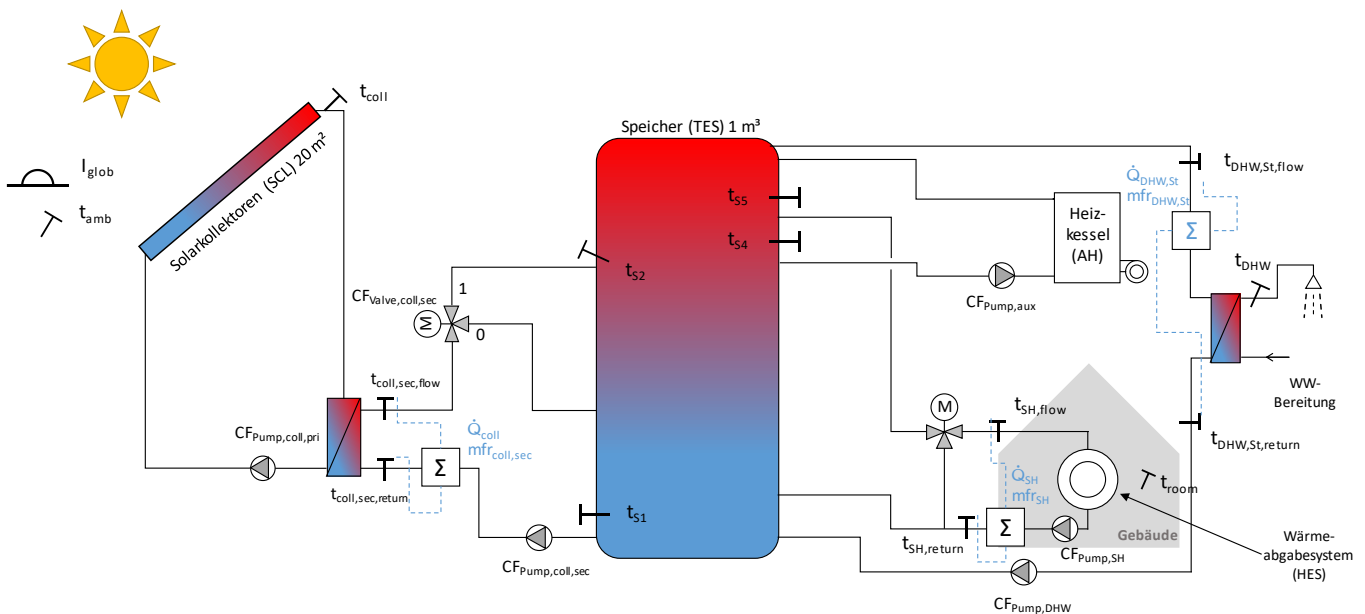


Abbildung 3: Schema des solaren Kombisystems.

Der Heizkessel hat eine Leistung von 10 kW und ist an den oberen Teil des TES angeschlossen, das Nachheiz-Volumen beträgt 300 Liter. Die Warmwasserbereitung erfolgt über ein Frischwassermodul, d.h. das Warmwasser wird bei Bedarf in einem Plattenwärmetauscher mit heißem Wasser aus dem TES auf die erforderliche Temperatur von 45 °C erwärmt. Der Wärmetauscher wird mit dem Modell Type 805 (Haller, 2007) modelliert, das intern den Durchfluss ermittelt, der auf der warmen Seite notwendig ist, um die eingestellte Austrittstemperatur auf der Trinkwasserseite zu erreichen. Das verwendete Zapfprofil für Warmwasser wurde mit der Software DHWcalc (Jordan und Vajen, 2012) erstellt. Diese Software verwendet statistische Wahrscheinlichkeiten für verschiedene Arten von Zapfungen bzgl. Durchfluss und

Dauer, was zu einem unterschiedlichen Zapfverhalten für jeden Tag führt. Der resultierende jährliche Gesamtwärmebedarf für Warmwasser beträgt 3043 kWh/a.

## Regelung

Die im System implementierte Standardregelung (Hysterese-Regelung) wird hier für die einzelnen Systemteile beschrieben.

**Solarkreis:** Die Pumpe  $P_{\text{coll,pri}}$  wird eingeschaltet, wenn  $t_{\text{coll}} > (t_{S1} + 7 \text{ K})$  ist, wobei  $t_{\text{coll}}$  die Wärmeträger-Temperatur am Ausgang des Kollektors und  $t_{S1}$  die Wassertemperatur im unteren Bereich des Speichers ist (siehe Abbildung 3). Nachdem  $t_{\text{coll}}$  auf  $t_{S1} + 4 \text{ K}$  gefallen ist, wird die Pumpe wieder abgeschaltet. Die Pumpe  $P_{\text{coll,sec}}$  im sekundären Kollektorkreislauf wird 6 Minuten nach  $P_{\text{coll,pri}}$  eingeschaltet und gleichzeitig mit der Pumpe im primären Kreislauf abgeschaltet. Das Dreiwegeventil wird in die obere Stellung ( $CF_{\text{Valve,coll,sec}}=1$ ) geschaltet, wenn  $t_{\text{coll,sec,flow}} > (t_{S2} + 3 \text{ K})$ . Fällt  $t_{\text{coll,sec,flow}}$  unter  $t_{S2}$ , wird das Ventil in die untere Stellung geschaltet.

**Nachheizung durch Kessel:** Die Nachheizung des oberen Speichervolumens wird eingeschaltet, wenn  $t_{S5} < (t_{\text{aux,set}} - 8 \text{ K})$  und ausgeschaltet, wenn  $t_{S4} < (t_{\text{aux,set}} - 2 \text{ K})$ . Die Solltemperatur des Kessels beträgt  $t_{\text{aux,set}} = 63 \text{ °C}$ .

**Warmwasserbereitung:** Der Volumenstrom auf der heißen Seite (vom TES kommend) des Wärmetauschers wird so geregelt, dass auf der Frischwasserseite des Wärmetauschers eine Austrittstemperatur von 45 °C erreicht wird.

## Simulationsergebnisse für die Standard-Konfiguration

Die Simulationen wurden mit einem konstanten Zeitschritt von 3 Minuten durchgeführt. Die Simulationsergebnisse wurden anhand des solaren Deckungsgrads (SF) als Kennzahl ausgewertet. Die verwendeten Abkürzungen sind in Abbildung 3 eingezeichnet. Für die Ausgangskonfiguration mit der Standardregelung beträgt der solare Deckungsgrad  $SF = 34,4 \%$ . Die Jahres-Wärmebilanz des Systems ist in Abbildung 4 dargestellt.

$$SF = 1 - \frac{Q_{\text{aux}}}{Q_{SH} + Q_{DHW}}$$

## Simulationsergebnisse als Datenbasis für weitere Analysen

In Abbildung 3 sind verschiedene Sensorpositionen eingezeichnet, die häufig in realen Systemen installiert sind. Es wird für die weiteren Arbeiten angenommen, dass deren Signale für die Analyse bzw. als Datengrundlage für KI-basierte Modelle und Regelungen verfügbar sind. Die Daten aller in Abbildung 3 dargestellten Sensoren wurden über die Dauer einer Jahres-Simulation aufgezeichnet, zum einen für jeden Zeitschritt (3 min) und zum anderen als stündliche Durchschnitts- bzw. Summenwerte. Diese Daten wurden in den späteren Arbeitspaketen verwendet, um Methoden zur Steuerung, Optimierung und der prädiktiven Regelung zu testen.




Abbildung 4: Jahres-Wärmebilanz des solaren Kombisystems; die linke Seite zeigt die Wärmeeinträge ( $Q_{coll}$ ...Kollektorkreislauf,  $Q_{aux}$ ...Kessel), die rechte Seite die Wärmeabflüsse ( $Q_{HES}$ ...Raumwärmebedarf,  $Q_{DHW}$ ...Warmwasserbedarf,  $Q_{coll,pipe,loss}$ ...Rohrleitungsverluste Kollektorkreislauf,  $Q_{aux,pipe,loss}$ ...Rohrleitungsverluste Kesselkreislauf,  $Q_{St,loss}$ ...Wärmeverluste Speicher).

### 3.3 Systemaufteilung in Subsysteme

Das solare Kombisystem kann als Summe der verschiedenen in Abbildung 5 dargestellten Teilsysteme modelliert werden. Die Temperatur und der Energieinhalt des Speichers (TES) hängen von der Wärmezufuhr aus dem Solarkreislaufs (SCL) und vom durch die Hysterese-Regelung aktivierten Kessel (AH) sowie von der Wärmeabfuhr über die Warmwasserbereitung und den Heizungskreislauf (HES) ab.

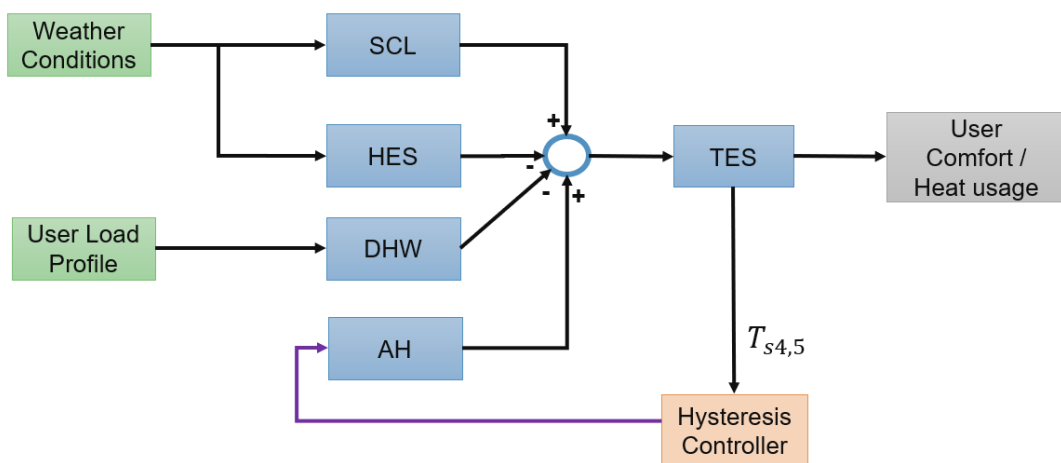


Abbildung 5: Blockschaltbild des solarthermischen Kombisystems.

Das Ziel einer modelprädiktiven Regelung, die im Projekt entwickelt wurde (Abschnitt 3.6) ist es, eine Strategie für möglichst minimale Energiebereitstellung durch den AH zu entwickeln. Die Strategie berücksichtigt Wettervorhersagen, um die möglichen zukünftigen Wärmeeinträge aus dem SCL und dem

Wärmeverbrauch des Heizkreises vorherzusagen. Mit diesen Vorhersagen kann die modellprädiktive Regelung eine optimale Regelungssequenz ermitteln, um die Aktivierung des Kessels zu minimieren und gleichzeitig die für die Komfortvorgaben notwendigen Temperaturen im Speicher zu gewährleisten.

Für dieses Konzept waren 3 Modelle zu entwickeln:

- Ein Modell für die SCL, um den künftigen Wärmeeintrag in den TES anhand von Wettervorhersagen prognostizieren zu können.
- Ein Modell für das HES zur Vorhersage der zukünftigen Last.
- Ein Modell für den TES als Grundlage für den modellprädiktiven Regler.

Es ist zu beachten, dass aufgrund des schlecht vorhersagbaren Warmwasserbedarfs kein Modell herangezogen wurde und dieser als Störung des Systems im Regelaufbau betrachtet wurde.

### 3.3.1 Beschreibung der Subsysteme

#### Solarkreislauf

Die vom Solarkreislauf bereitgestellte Leistung hängt von Umgebungsbedingungen wie der Außentemperatur, der Sonneneinstrahlung, der Tages- und Jahreszeit (Einstrahlwinkel) sowie von internen Faktoren wie der Temperatur im Speicher ab. Der Prädiktor für den Solarkollektor wurde anhand vergangener Werte folgender Größen trainiert:

- Tageszeit
- Jahreszeit
- Außentemperatur
- Temperatursensor im Speicher ( $T_{s1}$ )
- Solare Globalstrahlung ( $I_{glob}$ )
- Frühere Messungen der vom Solarkreis bereitgestellten Leistung ( $\dot{Q}_{coll}$ )

Die Vorhersage der Kollektorleistung  $\dot{Q}_{col}$  erfolgt für die nächsten 12 h. Ein Blockdiagramm des SCL-Modells ist in Abbildung 6 dargestellt.




Abbildung 6: Blockschaltbild des Prädiktors für den Solarkreislaufs.

Die Tages- und jahreszeitlich bedingten Leistungsschwankungen wurden über die Berücksichtigung der Tages- und Jahreszeit erfasst. Diese wurde jeweils über eine Sinus-Funktion mit passender Frequenz codiert, um dem verwendeten KI-Algorithmen das zyklische Verhalten besser vermitteln zu können („cyclic encoding“). Damit werden die im Tages- und Jahresverlauf variierenden Einfallswinkel der Sonnenstrahlung auf den Kollektor berücksichtigt.

## Wärmespeicher

Die Temperaturentwicklung im TES hängt von der Wärmezufuhr über den SCL und den AH, der Wärmeabfuhr über den HES, sowie der Temperatur des Sensors "Ts1" ab. Die Eingangs- und Ausgangssignale für das TES-Modell sind im Blockdiagramm in Abbildung 7 dargestellt.

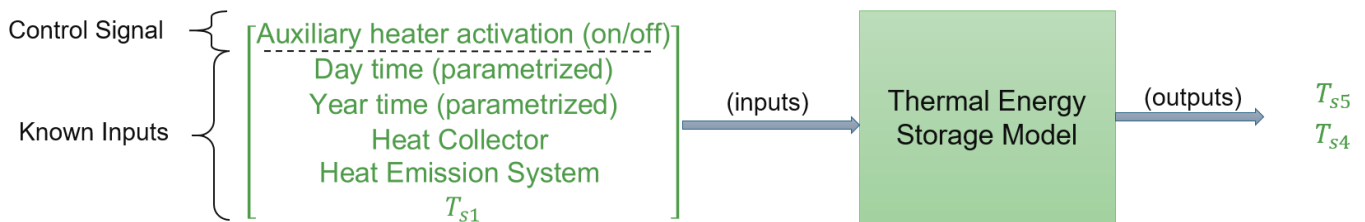


Abbildung 7: Blockschaltbild des TES Modells.

Hier ist zu beachten, dass die einzige Stellgröße des TES-Modells die Aktivierung des AH ist. Tageszeit, Jahreszeit, Wärmeleistung des Solarkreislaufs, Verbrauch des HES und Temperatur des Sensors "Ts1" werden im MPC-Setup als bekannte Eingaben betrachtet. Da die Warmwasserbereitung bzw. der Warmwasserbedarf ein sehr zufälliges Verhalten aufweist, wurde für diesen Eingang kein Prädiktor entwickelt. Der Warmwasserverbrauch wird als Störung für das System betrachtet und nicht als bekannter Eingang.

## Wärmeabgabesystem

Der Prädiktor für das Wärmeabgabesystem wird anhand vergangener Werte folgender Größen trainiert:

- Tageszeit
- Jahreszeit
- Außentemperatur ( $t_{amb}$ )
- Raumtemperatur ( $t_{room}$ )
- Solare Globalstrahlung ( $I_{glob}$ )
- Heizlast ( $\dot{Q}_{SH}$ )

Die Heizleistung  $\dot{Q}_{SH}$  wird für 12 h in die Zukunft vorhergesagt. Die Eingangs- und Ausgangssignale für das HES-Modell sind im Blockdiagramm in Abbildung 8 dargestellt.




Abbildung 8: Modell des Wärmeabgabesystems.

### 3.4 KI-basierte Modelle für den Solarkreislauf, das Wärmeabgabesystem und den Wärmespeicher

Datenbasierte Modellierungsverfahren (KI oder maschinelle Lerntechniken) bieten eine Alternative zu dem komplexen Prozess der physikalischen Modellierung (ZS Hou und Z Wang, 2013). Das Training von KI-Modellen hängt nur von den gemessenen Input-Output-Daten der untersuchten Anlage ab. Auf diese Weise können Modelle bei entsprechender Qualität der Messdaten die jeweilige Eingangs- und Ausgangsdynamik erfassen (z.B. Sensor- und Aktordynamik). Dies kann die Leistungsfähigkeit von Regelungssystemen erheblich verbessern.

Unter den zahlreichen Strukturen für datenbasierte Modelle sind Long-Short-Term Memory (LSTM), Convolutional Neural Networks (CNN) und Neuro-Fuzzy-Modelle die effizientesten Methoden, um das Verhalten komplexer dynamischer Systeme zu erfassen, d.h. Modelle, die auf gemessenen Zeitreihendaten basieren (J. Rehr et al. 2019, J. Rehr et al. 2014, D. Schwingshackl et al. 2016, O. Nelles, 2001). Im Projekt wurden einzelne Systemteile (siehe 3.3) mittels geeigneter KI-basierter Ansätze modelliert.

#### 3.4.1 LSTM

Da die Daten aus den TRNSYS-Simulationen im Projekt in Form von Zeitreihen vorliegen, wurde ein geeignetes Modell benötigt. Deshalb wurde nach einiger Literaturrecherche das LSTM oder Long-Short-Term-Memory (LSTM)-Netz gewählt. LSTMs sind eine spezielle Art von rekurrenten neuronalen Netzen, die in der Lage sind langfristige Abhängigkeiten zu verarbeiten. LSTMs enthalten drei verschiedene Eingänge, um optional Informationen durchzulassen. Diese Eingänge können entweder irrelevante Informationen vergessen, neue Informationen hinzufügen oder aktualisierte Informationen durchlassen. Die Funktionen innerhalb der Eingänge berechnen, welche Aktionen durchgeführt werden müssen. LSTM Netze wurden für den Solarkreislauf und die Heizleistung des Wärmeabgabesystems verwendet.

#### 3.4.2 CNN

Neben dem LSTM können auch Convolutional Neural Networks (CNNs) zur Vorhersage von Zeitreihendaten verwendet werden. CNNs können eingesetzt werden, indem Faltungen an den eindimensionalen Zeitreihendaten vorgenommen werden. Dies dient der Extraktion relevanter Informationen entlang der Zeitdimension. CNN Netze wurden für den Solarkreislauf und die Heizleistung des Wärmeabgabesystems verwendet.

#### 3.4.3 Autoregressives Modell / Ansatz der externen Dynamik

Ein Modell kann so trainiert werden, dass es  $n$  Eingabegrößen erhält und eine Ausgabegröße vorhersagt. Sobald das Modell aufgerufen wird, wird die resultierende Vorhersage zur Eingabe hinzugefügt und das Modell erneut aufgerufen, was zu einer neuen Vorhersage führt. Dies kann für eine beliebige Anzahl von Eingabegrößen durchgeführt werden und hat den Vorteil, dass der Benutzer nicht auf die trainierte Anzahl von Ausgabeschritten beschränkt ist. Autoregressive Modelle wurden für den Solarkreislauf und die Heizleistung des Wärmeabgabesystems verwendet.

### 3.4.4 Neuro-Fuzzy Modell (NFM)

Für die Simulation des Verhaltens des Wärmespeichers wurde ein NFM-Modell-Ansatz erprobt. Das NFM ist ein allgemeiner Approximator, der verschiedene lokale lineare Modelle (LLMs) über Gewichtungsfunktionen (Gültigkeitsfunktionen, VF) interpoliert (siehe J. Rehrl et al. 2019, O. Nelles, 2001). Jedes LLM ist mit einer eindeutigen VF verbunden, die den Gültigkeitsbereich der Operation bestimmt. Jedes LLM hat die Form

$$\hat{y}_{l,k} = \omega_{l,0} + \sum_{i=1}^N \left( \omega_{l,i}^y y_{k-i} + \sum_{j=1}^m \omega_{l,i}^{u_j} u_{j,k-i} \right),$$

wobei  $\hat{y}_{l,k}$  die Ausgabe des  $i$ -ten LLM zum Zeitpunkt  $k$  ist und  $\omega_{l,i}^y$  und  $\omega_{l,i}^{u_j}$  (dessen Parameter sind.  $N$  ist die Anzahl der Input-Output-Verzögerungen im autoregressiven oder extern-dynamischen Ansatz,  $m$  ist die Anzahl der physikalischen Systemeingänge.

Der Gesamt-Output des Modells ist eine gewichtete Summe aller LLMs durch eine normierte Gaußfunktion. Zu beachten ist, dass der Vektor,

$$\bar{u}_k = [y_{k-1}, y_{k-2}, \dots, y_{k-N}, u_{1,k-1}, u_{1,k-2}, \dots, u_{1,k-N}, u_{2,k-1}, \dots, u_{2,k-N}, \dots, u_{m,k-1}, \dots, u_{m,k-N}]^T$$

bestehend aus den verzögerten (alten) Werten der Ein- und Ausgänge für den Ansatz der externen Dynamik bestimmt ist. Damit folgt die Beschreibung

$$\hat{y}_k = \sum_{l=1}^M \hat{y}_{l,k} \Phi_l(\bar{u}_k)$$

mit den Gewichtungsfunktionen

$$\Phi_l(\bar{u}_k) = \frac{\mu_l(\bar{u}_k)}{\sum_{j=1}^M \mu_j(\bar{u}_k)},$$

$$\mu_l(\bar{u}_k) = \exp\left(-\frac{1}{2} \left( \sum_{j=1}^{N(m+1)} \frac{(\bar{u}_k(j) - c_{l,j})^2}{\sigma_{l,j}^2} \right)\right).$$

## 3.4.5 Lineare Regression

Für die Prognose der Heizleistung wurde auch die Methode der linearen Regression im Projekt erprobt, wobei ein ähnlicher Ansatz verwendet wurde, wie er in Nitz und Gölles (2019) beschrieben ist. Dabei wird methodisch folgendermaßen vorgegangen:

- Training (Regression) des Modells mit den Daten der vorhergehenden n Tage
- Laufende tägliche Neuberechnung der Regressions-Koeffizienten
- Separate Modelle / Koeffizienten für jede Stunde des Tages
- Prognose der Heizlast für die nächsten 24 h basierend auf einer (idealen) Wetterprognose (Außentemperatur und Globalstrahlung)

Die Berechnungen wurden dabei basierend auf den Simulationsdaten durchgeführt, die mit einer Auflösung von 1 h im Projekt vorlagen. Der Ablauf der einzelnen Schritte für die Berechnung der Prognose für  $\dot{Q}_{SH}$  ist in Abbildung 9 dargestellt.

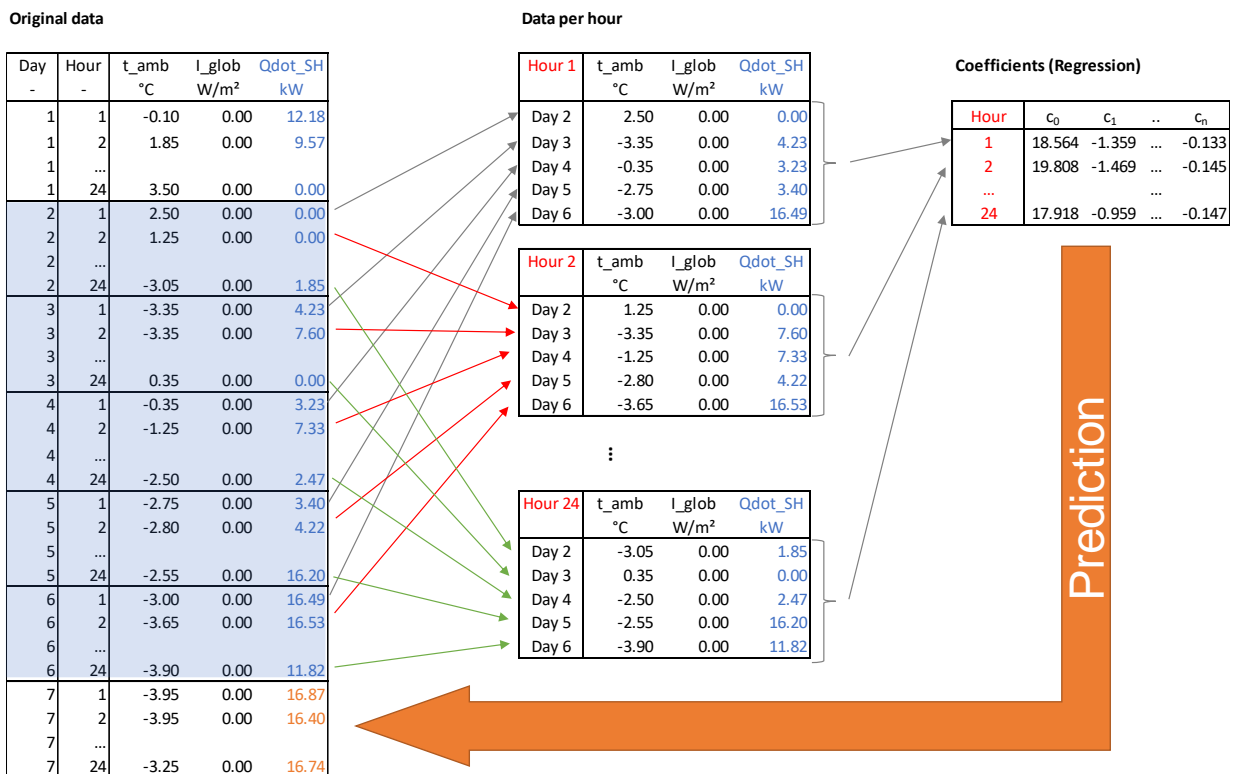


Abbildung 9: Ablaufschema für die Prognose von  $\dot{Q}_{SH}$  mittels linearer Regression. In diesem Beispiel wird exemplarisch eine Prognose für Tag 7 anhand der Daten der Tage 2-6 erstellt.

Als Input-Daten für die Regression dienten dabei die Stundendaten der Außentemperatur, der Globalstrahlung, der Tageszeit (Stunde des Tages) und der tatsächlichen (simulierten) Heizleistung.

### 3.4.6 Bewertungsgrößen für die Performance der Modelle

Für die Bewertung der Modelle wurden die folgenden Größen herangezogen:

- Mittlerer quadratischer Fehler (MSE)
- Mittlerer absoluter Fehler (MAE)
- Bestimmtheitsmaß ( $R^2$ )

## 3.5 Datenaufbereitung und Training

Die Aufbereitung der Simulationsdaten erfolgte in den folgenden Schritten:

- Erkennung und Entfernung von Ausreißern
- Normierung
- Downsampling von 3 min auf 15 min.

Durch die Analyse der Daten und die Anwendung von Prozesswissen ist es möglich, Ausreißer in den Daten zu erkennen. Die Ausreißer wurden entfernt, um die Qualität der späteren Berechnungen nicht zu beeinträchtigen. Nach der Filterung der Ausreißer wurden die Datensätze zwischen 0 und 1 normiert. Zusätzlich wurden zwei Merkmale hinzugefügt, die Tageszeit und die Jahreszeit, die als Sinuswellen mit den entsprechenden Perioden parametrisiert sind, wie bereits in Abschnitt 3.3.1 erläutert (Abbildung 10). Die Abbildung 11 zeigt die normierten und down-gesampelten Daten, wie sie für die Prädiktoren verwendet wurden.




Abbildung 10: Parametrisierte Tages- und Jahreszeit für 15-Minuten Zeitschritte.

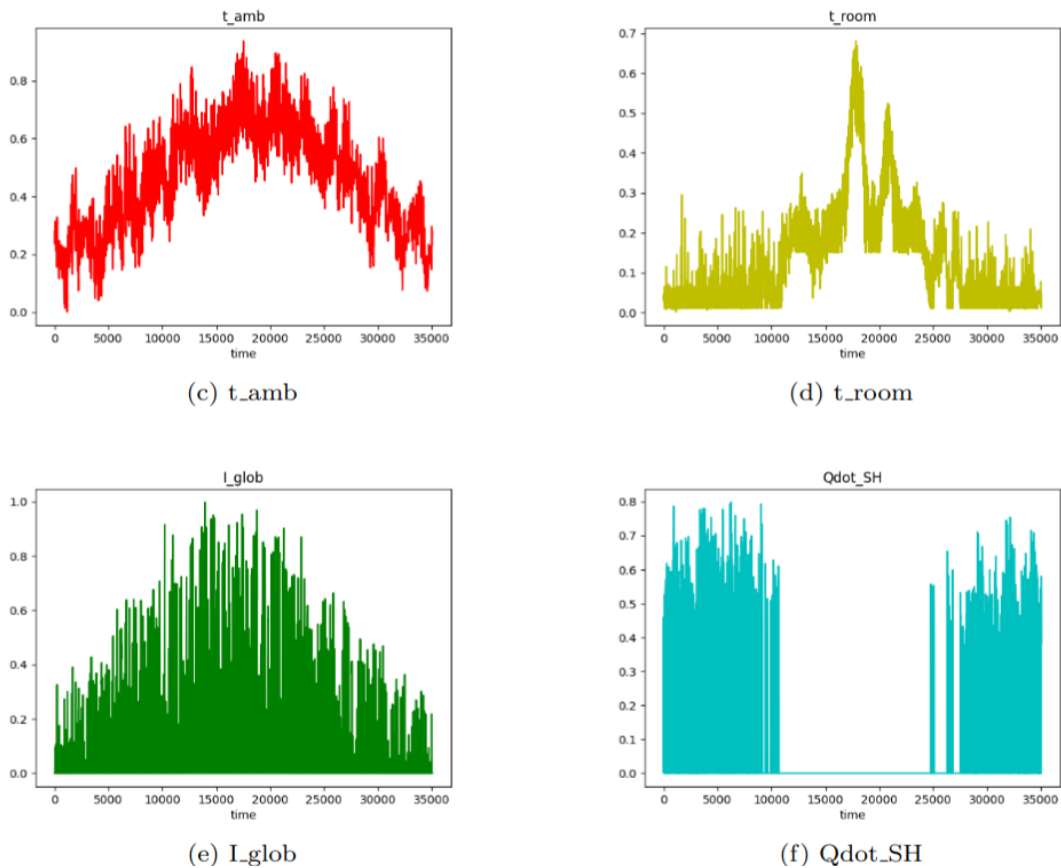


Abbildung 11: Normierte und down-gesampelte Daten für die Prädiktoren.

Bei der Wahl einer geeigneten Sampling-Zeit für die Modelle wurde einerseits berücksichtigt, dass diese kurz genug sein muss, um die Systemdynamik angemessen zu erfassen, und andererseits die Komplexität der resultierenden Modelle. Nach einem iterativen Prozess des Trainings, der Leistungs- und Komplexitätsüberprüfung wurden die Daten von 3-Minuten-Schritten auf 15-Minuten-Schritte heruntergerechnet. Dies geschah durch die Berechnung des Durchschnitts von jeweils 5 Samples.

## Training

Zum Trainieren und Testen der LSTM- und CNN-Modelle wurden drei Datensätze verwendet. Für das Training wurde ein simuliertes Jahr mit einem kalten Klimadatensatz, für die Validierung der Trainingsdaten ein Jahr mit einem wärmeren Klima und für den Test ein Jahr mit einem mittleren Klimadatensatz verwendet. Es wurden verschiedene Parameterkonfigurationen getestet, um das Modell mit der besten Leistung zu ermitteln. Die getesteten Parameter sind unten aufgeführt.

Bei den Ergebnisdaten handelt es sich um Zeitreihen. In den csv-Dateien für das kalte, warme und mittlere Klima entspricht jede Zeile den Größen eines Zeitschritts. Um die Zeitreihendaten korrekt vorherzusagen zu können, wurde ein Data-Windowing vorgenommen. Das bedeutet, dass die Daten so angeordnet wurden, dass der Input immer aus einer Anzahl von Input-Schritten besteht und jeder Input-Schritt aus den 6 Größen besteht, die für die jeweilige Vorhersage verwendet werden. Da auf der Grundlage der

Inputgrößen eine Anzahl von Ausgabeschritten vorhergesagt werden soll, mussten die Ausgabeschritte als Labels angeordnet werden. In Abbildung 12 wird dieser Prozess veranschaulicht.

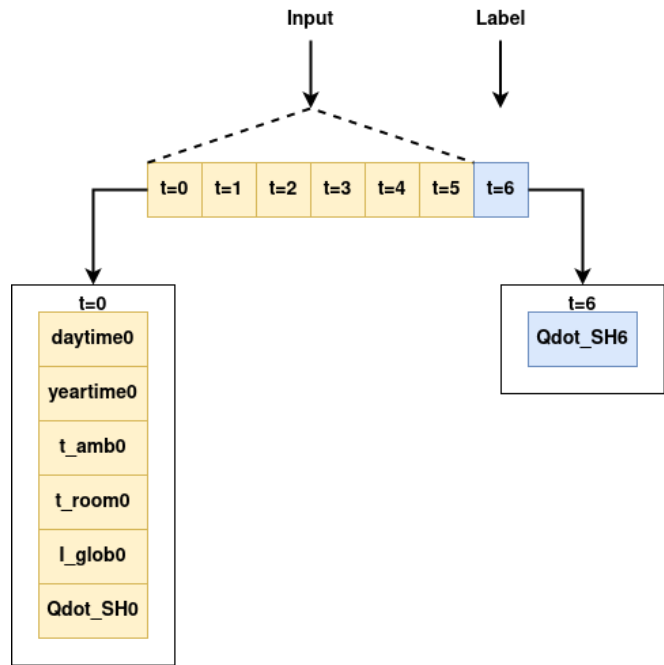


Abbildung 12: Beispiel für auto-regressive Inputs.

Hier wird angenommen, dass das Modell so trainiert werden soll, dass es die Werte der letzten 6 Zeitschritte als Input verwendet und darauf basierend einen Zeitschritt in die Zukunft voraussagt. Das Ziel des Gebäudemodells ist die Vorhersage der Heizlast  $\dot{Q}_{SH}$ , weshalb jeder Ausgangswert nur aus der Zielgröße besteht.

## Trainings-Algorithmus für die Bestimmung der Parameter der NF-Modelle (Local Linear Model Tree Algorithmus)

Der LoLiMoT-Trainingsalgorithmus ist ein schnell-inkrementeller Konstruktionsalgorithmus, der eine heuristische Strategie für die Aufteilung des Eingaberaums mit der lokalen linearen Optimierung der kleinsten Quadrate (LSO) kombiniert. Die LSO wird für die Identifizierung der linearen Parameter  $\omega_l$  verwendet. Der Eingaberaum wird Achsen-orthogonal partitioniert, was zu Hyperrechtecken führt, in deren Zentren die Gauß'schen Membership-Funktionen platziert werden. Die Standardabweichungen dieser Membership-Funktionen hängen von der Länge der Hyperrechtecke ab. Daher werden die nichtlinearen Parameter für die Zentren und Standardabweichungen durch einen heuristischen Ansatz und nicht durch nichtlineare Optimierung bestimmt.

Die Identifikationsphase und das daraus resultierende Modell hängen weitgehend von der Qualität der entworfenen Erregungssignale ab, die der Anlage zugeführt werden. Diese Phase kann durch iterative Trainings- und Validierungstests bewertet werden (siehe Abschnitt 4).

### 3.6 Regelungsansatz für eine modellprädiktive Regelung (MPC) des betrachteten Systems

Im Projekt wurde untersucht, ob für das betrachtete wärmetechnische System (Abschnitt 3.2) eine Modellprädiktive Regelung (J. B. Rawlings, D. Q. Mayne, 2015) auf Grundlage von KI-basierten Modellen für einzelne Systemteile umgesetzt werden kann. Für das Regelungssystem wurden zwei allgemeine Ziele berücksichtigt:

1. Die Integration eines NFM-LoLiMoT-Modells als Ersatz für ein physikalisches Modell des Wärmespeichers, was den Aufwand für die mathematische Modellentwicklung reduziert.
2. Nutzung der Vorhersagen für den solaren Energieinput und den Heizungs-Wärmeverbrauch zur Reduktion der Wärmebereitstellung durch den Kessel.

Die in Abschnitt 3.2 beschriebene Standardregelung (Hysterese-Regelung) wurde als Grundlage für den Regelungsansatz betrachtet. Diese funktioniert wie folgt:

- Die Nachheizung wird aktiviert, wenn die Temperatur am Sensor  $T_{s5}$  weniger als  $55\text{ °C}$  beträgt
- Die Zusatzheizung wird deaktiviert, wenn die Temperatur am Sensor  $T_{s4}$  gleich oder größer als  $58\text{ °C}$  ist.

Der MPC-Regelungsansatz ist eine Kombination aus dem Verhalten der Hysterese-Regelung und der Implementierung des MPC-Algorithmus zur Sollwertverfolgung, d.h.:

- Der MPC-Algorithmus wird aktiviert, wenn die Temperatur am Sensor  $T_{s5}$  unter  $55\text{ °C}$  fällt.
- Der MPC-Algorithmus regelt die Temperatur des Sensors  $T_{s4}$  auf  $58\text{ °C}$  unter Berücksichtigung der Prognosen für den solaren Energieinput und den Heizungs-Wärmeverbrauch.
- Der MPC-Algorithmus wird deaktiviert, wenn die Temperatur am Sensor  $T_{s4}$   $58\text{ °C}$  oder mehr erreicht.

Der Vorteil dieses Ansatzes besteht darin, dass die Prognosen für den solaren Energieinput und den Heizungs-Wärmeverbrauch (Wettervorhersagen) vom Regler in der Heizungsphase berücksichtigt werden. Energieeinsparungen sollen ermöglicht werden, indem der Kessel vor Erreichen von  $58\text{ °C}$  abgeschaltet wird, wenn solarer Energieinput erwartet wird und  $58\text{ °C}$  ohne Kessel erreicht werden können.

Für den MPC-Ansatz werden die Eingangssignale des NFM-LoLiMoT-Modells in verschiedene Gruppen aufgeteilt:

**Stellgröße:** Die Aktivierung des Kessels ist die einzige Stellgröße.

**Bekannte Eingänge:** Der Wärmebereitstellung durch die Solaranlage und der Heizungs-Wärmeverbrauch sind bekannte Eingänge, ebenso wie die parametrisierte Zeit.

**Regelungsgrößen:** Schätzung der Temperatursensoren "Ts4" und "Ts5".

**Störung:** Der Wärmebedarf für Warmwasser wird als Störgröße (unbekannter Eingang) für das System betrachtet.

In jeder Sampling-Zeit (15 Minuten) löst der MPC ein gemischt-ganzzahliges quadratisches Optimierungsproblem unter Berücksichtigung der Nebenbedingungen und der Systemdynamik, bei dem eine ganzzahlige (Ein/Aus-Signale) optimale Regelungssequenz gefunden wird, so dass eine vordefinierte Kostenfunktion minimiert wird. Die Kostenfunktion gewichtet den Tracking-Fehler des Temperatursensors "Ts4" gegenüber dem gewünschten Sollwert von 58 °C und das Aktivierungssignal des Kessels. Die Gewichte dieser Kostenfunktion wurden iterativ durch Simulationen ausgewählt.

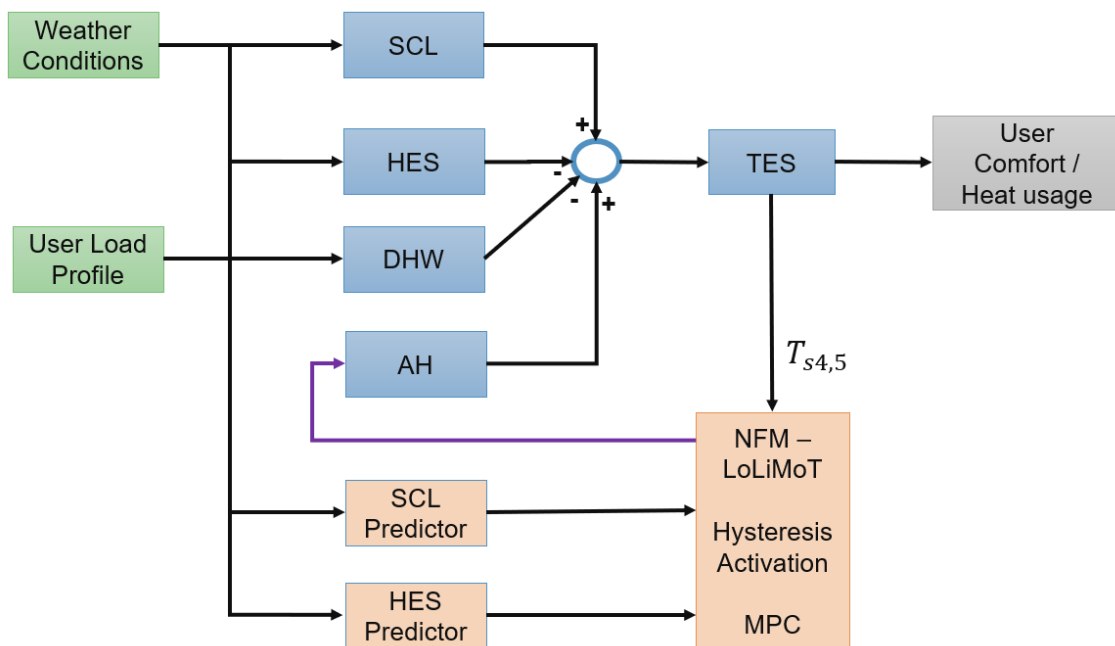


Abbildung 13: Blockdiagramm der prädiktiven Regelung. Die Vorhersagen der SCL- und HES-Modelle werden in den MPC-Vorhersagehorizonten berücksichtigt, so dass der AH-Verbrauch aufgrund der vorhergesagten Wärmeeinträge aus den Wettervorhersagen reduziert werden kann.

### Interne Berechnung im MPC-Block.

Das NFM wird in eine State-Space-Darstellung transformiert, indem die Parameter wie folgt umgeschrieben werden:

$$\hat{y}_k = \sum_{i=1}^N \left( -a_{N-i,k} y_{k-i} + \sum_{j=1}^m b_{N-i,k}^j u_{j,k-i} \right) + w_{d,k}$$

$$\omega_{d,k} = \sum_{l=1}^M \omega_{l,0} \Phi_l(\bar{u}_k)$$

$$b_{N-i,k}^j = \sum_{l=1}^M \omega_{l,i}^j \Phi_l(\bar{u}_k)$$

$$a_{N-i,k} = - \sum_{l=1}^M \omega_{l,i} \Phi_l(\bar{u}_k)$$

Der Zustandsvektor  $x_k$  und der Eingangsvektor  $u_k$  werden in folgender Form definiert:

$$x_k = [x_{y_1,k}^T, \dots, x_{u_2,k}^T, \dots, x_{u_m,k}^T]^T$$

$$u_k = [u_{1,k}, \dots, u_{n,k}]^T$$

$$x_{y_i,k} = [y_{i,k}, \dots, y_{i,k-N+1}]^T$$

$$x_{u_j,k} = [u_{j,k-1}, \dots, u_{j,k-N+1}]^T$$

Man erhält ein nichtlineares Modell, welches durch ein affines, zeitvariantes Modell der Form

$$x_{k+1} = f(x_k, u_k) = A_k(x_k, u_k)x_k + B_k(x_k, u_k)u_k + B_{c,k}(x_k, u_k)$$

beschrieben werden kann. Es ist zu beachten, dass NFM-Modelle für mehrere Inputs und nur einen Output definiert sind. Dennoch kann für jeden Output ein NFM unabhängig trainiert werden und dann für alle Outputs verkettet werden.

Ein zeitinvariantes System der Form

$$x_{k+1} = A_s x_k + B_s u_k + B_{c,s} \quad \text{mit} \quad A_s = A_k(x_s, u_s), B_s = B_k(x_s, u_s), B_{c,s} = B_c(x_s, u_s)$$

wird erhalten, das die Dynamik des Systems um einen (stationären) Betriebspunkt  $(x_s, u_s)$  approximiert. Man beachte, dass  $B_{c,s}$  eine konstante Matrix ist, die sich aus den konstanten Bias-Termen  $w_{l,0}$  und  $w_{d,k}$  ergibt. Da nicht alle Eingaben aus dem  $u_k$ -Vektor Stellgrößen sind, müssen die Matrizen  $B_s$  und  $B_{c,s}$  umgeformt werden. Der Vektor  $u_k$  wird in zwei Vektoren aufgeteilt:

$$u_k = \begin{bmatrix} u_M \\ u_N \end{bmatrix} \quad \begin{array}{l} \text{— Manipulated Variable} \\ \text{— Known inputs} \end{array}$$

$$u_M = [\text{Auxiliary heater activation (on/off)}]$$

$$u_N = \begin{bmatrix} \text{Day time (parametrized)} \\ \text{Year time (parametrized)} \\ \text{Heat Collector} \\ \text{Heat Emission System} \\ T_{s1} \end{bmatrix}$$

Die Matrix  $B_s$  ist also  $B_s = [B_M \ B_N]$  mit den entsprechenden Dimensionen. Um nur eine Stellgröße und 6 bekannte Eingaben plus den konstanten Term von  $B_{c,s}$  zu berücksichtigen, werden die folgenden Vektoren und Matrizen definiert:

$$B = [B_M]; u_k = u_M; B_d = [B_{c,s} \ B_N]; d_k = [u_c \ u_N^T]^T$$

Dann kann ein Prädiktionsmodell für  $N_p$  zukünftige Schritte erhalten werden (für weitere Details siehe Rawlings und Mayne 2015).

$$\begin{aligned} x_{k+1} &= A_s x_k + B_s u_{k-1} + B_s \Delta u_k + B_D d_k; u_k = u_{k-1} + \Delta u_k \\ x_{k+2} &= A_s x_{k+1} + B_s u_k + B_s \Delta u_{k+1} + B_d d_{k+1} \\ &= A_s^2 x_k + A_s B_s u_{k-1} + A_s B_s \Delta u_k + A_s B_d d_k + B_s u_{k-1} + B_s \Delta u_k + B_s \Delta u_{k+1} + B_d d_{k+1} \\ x_{k+N_p} &= \dots \end{aligned}$$

In einer kurzen Schreibweise lautet das Prädiktionsmodell:

$$\bar{x}_{k+1} = F x_k + G u_{k-1} + H \Delta \bar{u}_k + H_d \bar{d}_k$$

Die Kostenfunktion für das Optimierungsproblem wurde wie folgt definiert

$$J = \sum_{i=1}^{N_p} (\hat{y}_{k+i} - r_{k+i})^T Q_i (\hat{y}_{k+i} - r_{k+i}) + \sum_{i=1}^{N_c} u_{k+i-1}^T R_i u_{k+i-1}$$

Dabei ist  $N_p$  die Anzahl der Schritte des Prädiktionshorizonts,  $N_c$  die Anzahl der Schritte des Stellhorizonts,  $\hat{y}_{k+i}$  ist die Output-Vorhersage bei Schritt  $k$ .  $Q_i, R_i$  sind positiv semidefinite bzw. positiv definite Matrizen und  $r_{k+i}$  ist eine Referenz für  $\hat{y}_{k+i}$ .

Durch Umformung der Kostenfunktion, Einbeziehung des Prädiktionsmodells und Verwendung des prädizierten Fehlervektors bei verschwindender Stellgröße  $\bar{e}_k = F x_k + G u_{k-1} - \bar{r}_{k+1}$  sind weitere Vereinfachungen möglich. Die Variablen  $\bar{r}_{k+1}$  bzw.  $\bar{e}_k$  fassen jeweils alle Werte der Referenzgrößen bzw. des Fehlervektors über den Prädiktions-Horizont zusammen.

Zusammen mit der Formulierung aller Beschränkungen (in  $W$  und  $\bar{w}$ ) folgt die endgültige Formulierung des Optimierungsproblems in der Struktur eines quadratischen Programms:

$$\begin{aligned} &\min_{\Delta \bar{u}_k \in \mathbb{R}^{m N_c}} J(\Delta \bar{u}_k) \\ &\text{unter} \\ &W \Delta \bar{u}_k \leq \bar{w} \end{aligned}$$

mit der Zielfunktion

$$J(\Delta \bar{u}_k) = \Delta \bar{u}_k^T (H^T Q H + R) \Delta \bar{u}_k + 2 \Delta \bar{u}_k^T H^T Q e_k .$$

Dieses kann z.B. mit der Matlab Optimization Toolbox (siehe <https://www.mathworks.com>) und dem Solver MOSEK (siehe <https://www.mosek.com>) numerisch gelöst werden.

Die Abfolge der Schritte im internen MPC-Block ist in Abbildung 14 dargestellt.

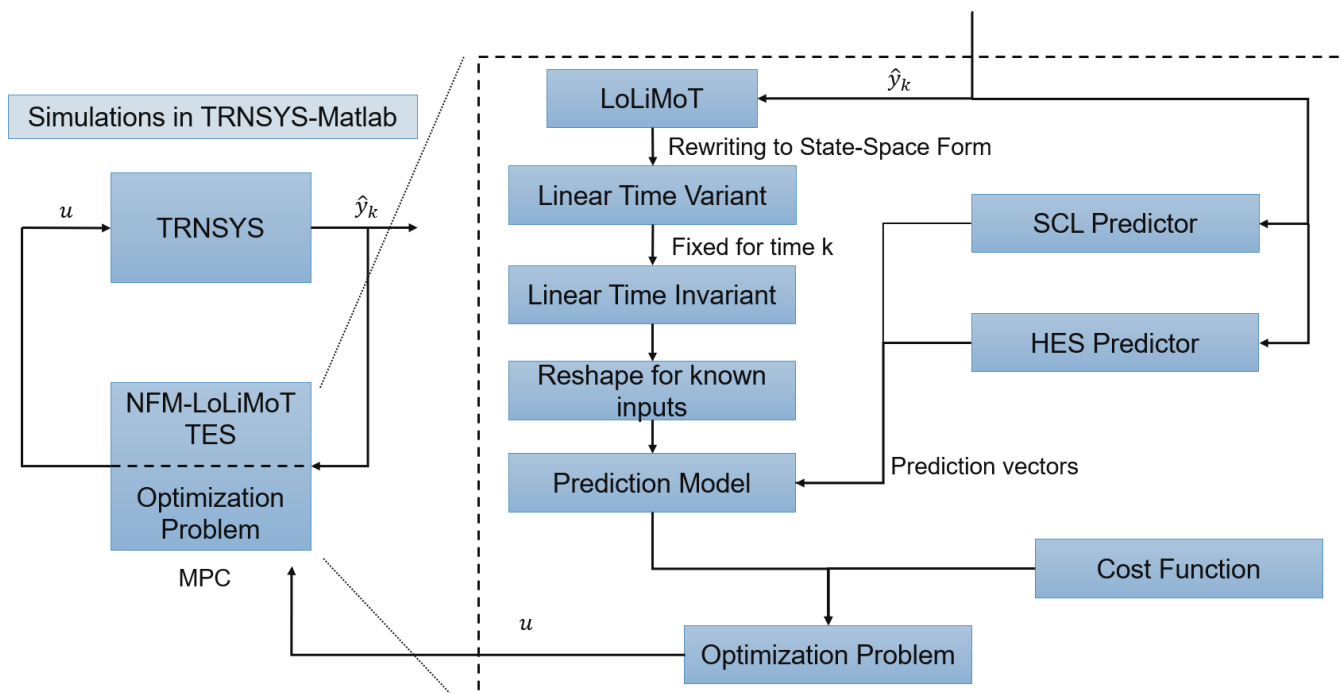


Abbildung 14: Interne Berechnungsschritte im Model Predictive Control Block.

## 4 Ergebnisse und Schlussfolgerungen

### 4.1 KI-basierte Modellierungs-Ansätze und deren Performance

Nach dem Training wurden die besten Modelle der drei Modelltypen verglichen. Es wurde festgestellt, dass CNN und LSTM ähnlich gut performen, während das autoregressive Modell schlechter abschneidet. Es ist anzumerken, dass die Performance der Netze mit zunehmender Anzahl von prognostizierten Zeitschritten abnimmt.

#### 4.1.1 CNN

##### Solarkreislauf

Wie erwähnt, nimmt die Performance der Modelle mit der Anzahl der Output-Samples (15-min-Zeitschritte) ab. In den folgenden Abbildungen werden die Vorhersagen (rot) eines CNN für den Solarkreislauf mit  $\dot{Q}_{coll}$  als Zielgröße mit den tatsächlichen Werten von  $\dot{Q}_{coll}$  (grün) aus den Simulationsdaten verglichen. Mit dem CNN wird ein  $R^2$  (Bestimmtheitsmaß) von etwa 0,67 erreicht (Tabelle 1, Abbildung 16). Für das neuronale Netz wurden 64 Neuronen und für das Training 300 Epochen mit einer Batch Size von 64 verwendet.

Tabelle 1: Performance-Kennzahlen (bezogen auf normierte Werte) mit dem CNN für 10 und 48 Samples (Zeitschritte) à 15 min

| Samples | MSE    | MAE    | R <sup>2</sup> |
|---------|--------|--------|----------------|
| 10      | 0,0021 | 0,0230 | 0,6677         |
| 48      | 0,0021 | 0,0225 | 0,4129         |

Um zu verstehen, wie die Vorhersagen funktionieren und farblich in den folgenden Grafiken zuzuordnen sind, dient Abbildung 15. Die Inputs für die nächste Vorhersage wären 6-11, um die Vorhersage von 12-18 zu erhalten. Auf diese Weise erscheinen die visualisierten Daten in den Abbildungen kontinuierlich.




Abbildung 15: Beispiel für die Vorhersage von 6 Samples basierend auf den vorhergehenden 6 Samples.




Abbildung 16: Vorhersage von  $\dot{Q}_{coll}$  (normiert) für 10 Samples à 15 min (2,5 h) mit dem CNN.

In Abbildung 17 ist das Ergebnis mit einem Modell dargestellt, das für die Vorhersage von 48 Samples in die Zukunft trainiert wurde. Es ist ersichtlich, dass die Performance schlechter ist als in Abbildung 16, wo nur 10 Samples prognostiziert wurden. Das Bestimmtheitsmaß  $R^2$  ist hier  $\sim 0,41$ .




Abbildung 17: Vorhersage von  $\dot{Q}_{coll}$  (normiert) für 48 Samples à 15 min (12 h) mit dem CNN.

## Heizleistung an das Gebäude

Im Vergleich zur Kollektorleistung performt das Modell für die Heizleistung, bei dem  $\dot{Q}_{SH}$  vorhergesagt wird, wesentlich besser. Auch hier wurden die besten Ergebnisse mit dem CNN erzielt. Für die Vorhersage

von 10 Samples wurde ein  $R^2$  von etwa 0,85 und für die Vorhersage von 48 Samples von ca. 0,72 ermittelt. Obwohl die Performance der Netze mit zunehmender Anzahl von Samples immer noch abnimmt, ist dies für  $\dot{Q}_{SH}$  weniger stark ausgeprägt als für  $\dot{Q}_{coll}$ . Ein Grund könnte sein, dass die Werte für  $\dot{Q}_{SH}$  regelmäßiger zu sein scheinen als jene für  $\dot{Q}_{coll}$ .

Tabelle 2: Performance-Kennzahlen (bezogen auf normierte Werte) mit dem CNN für 10 und 48 Samples à 15 min

| Samples | MSE     | MAE    | $R^2$  |
|---------|---------|--------|--------|
| 10      | 0,00873 | 0,0416 | 0,8487 |
| 48      | 0,00939 | 0,0453 | 0,7287 |

In Abbildung 18 werden die Ergebnisse eines Modells, das für die Vorhersage von 10 Samples trainiert wurde, mit den tatsächlichen Werten von  $\dot{Q}_{SH}$  verglichen. Die gute Performance des Modells ( $R^2 \sim 0,85$ ) kann visuell bestätigt werden.

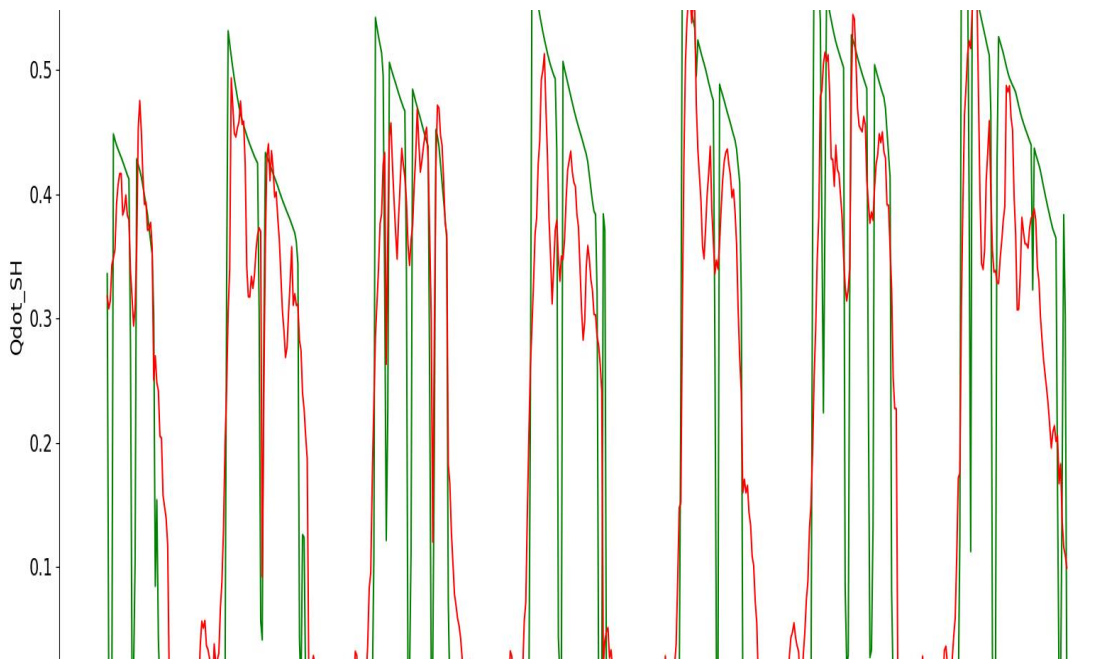


Abbildung 18: Vorhersage von  $\dot{Q}_{SH}$  (normiert) für 10 Samples à 15 min (2,5 h) mit dem CNN.

Bei der Vorhersage von 48 Samples ist der Rückgang der Genauigkeit der Vorhersagen besonders in den Bereichen zu beobachten, in denen  $\dot{Q}_{SH}$  auf Null fällt (Abbildung 19). Im Allgemeinen kann festgestellt werden, dass  $\dot{Q}_{SH}$  besser prognostiziert werden kann als  $\dot{Q}_{coll}$ . Der Grund dafür könnte sein, dass die für das Kollektorkreis-Modell gewählten Merkmale nicht so gut mit der Zielvariablen korrelieren.




Abbildung 19: Vorhersage von  $\dot{Q}_{SH}$  (normiert) für 48 Samples à 15 min (12 h) mit dem CNN.

## 4.1.2 LSTM

### Solarkreislauf

Wie beim CNN liefert das Modell des Solarkreislaufs schlechtere Ergebnisse als das Modell für die Heizleistung. Für den Solarkreislauf ist die Performance von LSTM und CNN sehr ähnlich und es ist nicht eindeutig, welches Modell besser abschneidet. Für die Vorhersage von 10 Samples beträgt  $R^2$  beim LSTM etwa 0,67, wie in Abbildung 20 ersichtlich.

Tabelle 3: Performance-Kennzahlen (bez. auf normierte Werte) mit dem LSTM für 10 und 48 Samples à 15 min

| Samples | MSE     | MAE    | $R^2$  |
|---------|---------|--------|--------|
| 10      | 0,00122 | 0,0165 | 0,6707 |
| 48      | 0,00215 | 0,0222 | 0,4122 |




Abbildung 20: Vorhersage von  $\dot{Q}_{coll}$  (normiert) für 10 Samples à 15 min (2,5 h) mit dem LSTM.

Für die Vorhersage von 48 Samples liegt  $R^2$  für das LSTM-Modell bei etwa 0,41, die Ergebnisse sind in Abbildung 21 dargestellt.




Abbildung 21: Vorhersage von  $\dot{Q}_{coll}$  (normiert) für 48 Samples à 15 min (12 h) mit dem LSTM.

## Heizleistung an das Gebäude

Für die Prognose der Heizleistung performt das LSTM-Netz etwas besser als das CNN, wobei  $R^2$  für die Vorhersage von 10 Samples bei etwa 0,87 und für die Vorhersage von 48 Samples bei etwa 0,72 liegt. Die Ergebnisse für 10 Samples sind in Abbildung 22 und jene für 48 Samples in Abbildung 23 dargestellt.

Tabelle 4: Performance-Kennzahlen (bez. auf normierte Werte) mit dem LSTM für 10 und 48 Samples à 15 min

| Samples | MSE     | MAE    | R <sup>2</sup> |
|---------|---------|--------|----------------|
| 10      | 0,00440 | 0,0260 | 0,8707         |
| 48      | 0,00957 | 0,0445 | 0,7251         |




Abbildung 22: Vorhersage von  $\dot{Q}_{SH}$  (normiert) für 10 Samples à 15 min (2,5 h) mit dem LSTM

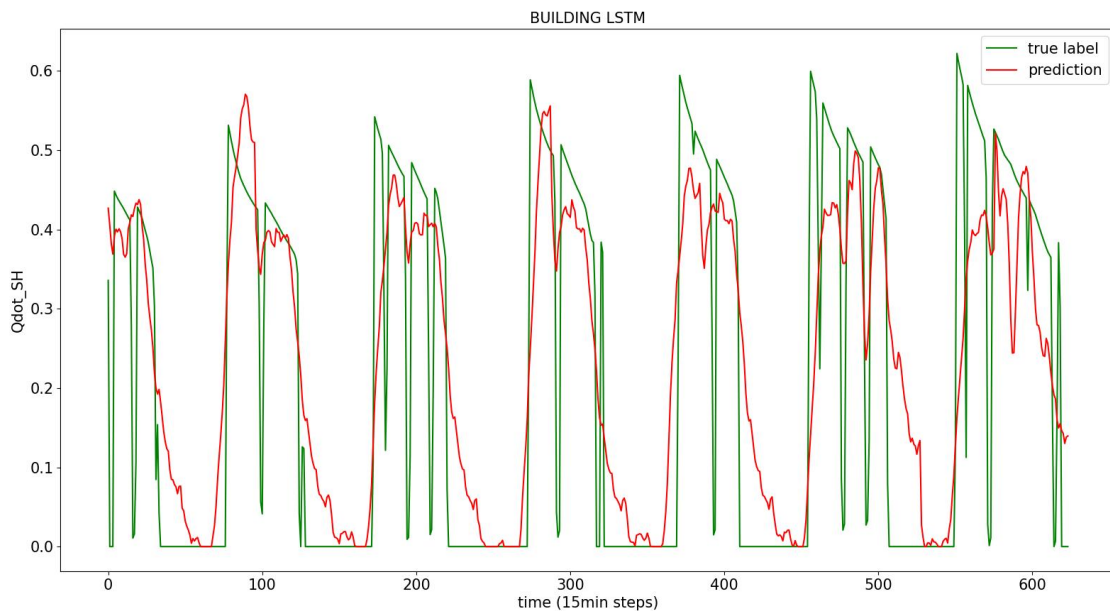


Abbildung 23: Vorhersage von  $\dot{Q}_{SH}$  (normiert) für 48 Samples à 15 min (12 h) mit dem LSTM

### 4.1.3 Autoregressives Modell

Die Ergebnisse des autoregressiven Modells waren schlechter ab jene des LSTM oder des CNN. Das Modell für den Solarkreis lieferte hier ein  $R^2$  von 0,64 für die Prognose von 10 Samples und  $R^2=0,4$  für 48 Samples. Für die Heizleistung wurde für 10 Samples ein  $R^2$  von 0,83 und für 48 Samples von 0,71 erzielt.

Tabelle 5: Performance-Kennzahlen (bez. auf normierte Werte) mit dem autoregressiven Modell für 10 und 48 Samples à 15 min

| Samples        | MSE     | MAE    | $R^2$  |
|----------------|---------|--------|--------|
| Solarkreislauf |         |        |        |
| 10             | 0,00137 | 0,0172 | 0,6408 |
| 48             | 0,00222 | 0,0216 | 0,3959 |
| Heizleistung   |         |        |        |
| 10             | 0,00579 | 0,0301 | 0,8332 |
| 48             | 0,00980 | 0,0440 | 0,7143 |

### 4.1.4 Monatsweise Modelle

Bisher wurden die Modelle für ein ganzes Jahr an Daten trainiert. Ein nächster Ansatz bestand darin, Monatsmodelle zu trainieren, also insgesamt 12 Modelle für jeden Monat des Jahres.

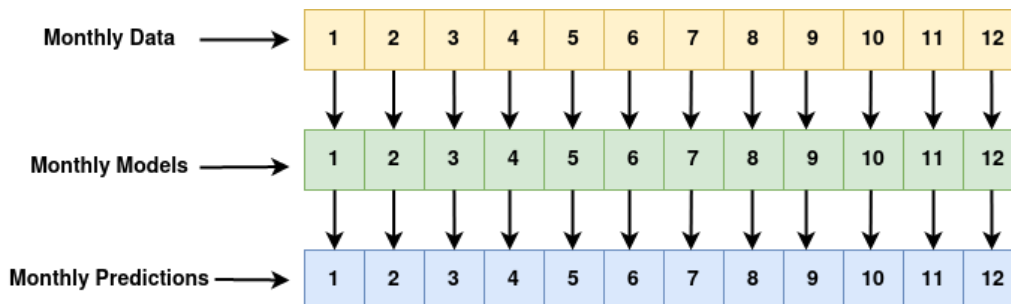


Abbildung 24: Schema der monatsweisen Modellierung

Jedes Modell wurde einzeln bewertet, indem die Vorhersagen mit dem entsprechenden Monat der Simulationsdaten verglichen wurden. Eine interessante Beobachtung beim Testen verschiedener Parameter war, dass die Genauigkeit der Vorhersagen für die verschiedenen Monate variiert.

Eine Auswertung für das CNN-Modell für den Kollektorkreislauf zeigt, dass bzgl.  $R^2$  die Qualität der Vorhersage zwischen den Monaten um bis zu 30 Prozentpunkte variiert. Im Mittel über alle Monate zeigte sich in diesem Beispiel, dass die Performance ( $R^2 \sim 0,63$ ) nicht besser ist als mit einem Modell für das gesamte Jahr ( $R^2 \sim 0,66$ ).

### 4.1.5 Lineare Regression

Mittels linearer Regression wurde versucht, die Heizleistung des Gebäudes  $\dot{Q}_{SH}$  zu prognostizieren. Dabei wurden die Regressions-Koeffizienten jeden Tag neu anhand der Daten aus den vorhergehenden 30 Tagen aktualisiert (siehe Abschnitt 3.4.5). Dabei wurden unterschiedliche Größen in das Modell

miteinbezogen. Abbildung 25 zeigt die Ergebnisse, für eine Regression rein über die Außentemperatur  $t_{amb}$ , also

$$\dot{Q}_{SH} = c_0[m] + c_1[m] t_{amb}$$

wobei die Koeffizienten  $c_0$  und  $c_1$  für jede Stunde des Tages (m) separat ermittelt wurden, wie in Abschnitt 3.4.5 beschrieben. Die Ergebnisse zeigen, dass bereits so eine relativ gute Prognose möglich ist.




Abbildung 25: Vorhersage von  $\dot{Q}_{SH}$  für einen exemplarischen Zeitraum von 21 Tagen; Regression nur über die Außentemperatur.

Da auch die Sonneneinstrahlung einen signifikanten Einfluss auf die notwendige Heizlast hat, wurde zusätzlich die Globalstrahlung berücksichtigt, also

$$\dot{Q}_{SH} = c_0[m] + c_1[m]t_{amb} + c_2[m] I_{glob}$$

Diese Ergebnisse sind in Abbildung 26 dargestellt. Es zeigt sich eine etwas bessere Übereinstimmung der Resultate im Vergleich zu Abbildung 25. Das Bestimmtheitsmaß kann auf  $R^2 = 0,61$  gegenüber der Variante mit einer Regression rein über die  $t_{amb}$  gesteigert werden ( $R^2 = 0,6$ , siehe Tabelle 6).




Abbildung 26: Vorhersage von  $\dot{Q}_{SH}$  für einen exemplarischen Zeitraum von 21 Tagen; Regression über die Außentemperatur und die Globalstrahlung.

Aufgrund der Überlegung, dass die Sonneneinstrahlung aufgrund der Speichermassen im Gebäude eher etwas zeitversetzt bzw. über eine längere Dauer wirksam wird, wurde auch eine Variante betrachtet, in der die Summe der Globalstrahlung über die vergangenen 24 h ( $I_{glob,24h}$ ) als Parameter in die Regression miteinbezogen wurde. Die dazugehörigen Ergebnisse in Abbildung 27 zeigen eine weitere Verbesserung der Übereinstimmung. Das Bestimmtheitsmaß  $R^2$  kann auf ca. 0,66 erhöht werden (Tabelle 6).




Abbildung 27: Vorhersage von  $\dot{Q}_{SH}$  für einen exemplarischen Zeitraum von 21 Tagen; Regression über die Außentemperatur und die 24-h-Summe der Globalstrahlung.

Tabelle 6: Performance-Kennzahlen (bezogen auf normierte Stunden-Werte) für die verschiedenen Varianten des Regressions-Modells

| Regressions-Parameter   | MSE    | MAE    | $R^2$  |
|-------------------------|--------|--------|--------|
| $t_{amb}$               | 0,0146 | 0,0567 | 0,6035 |
| $t_{amb}, I_{glob}$     | 0,0142 | 0,0545 | 0,6139 |
| $t_{amb}, I_{glob,24h}$ | 0,0127 | 0,0497 | 0,6565 |

In Abbildung 28 ist ein Vergleich zwischen den Simulationsdaten und den Prognose-Ergebnissen für Stundenwerte und den 24h-Mittelwert der Heizleistung für alle drei Varianten dargestellt. Während die Übereinstimmung für die stündlichen Leistungswerte in dieser Darstellung nicht allzu gut erscheint, ergibt sich insbesondere für die Variante mit Einbeziehung von  $I_{glob,24h}$  eine gute Übereinstimmung der mittleren Heizleistung über 24 h. Es sollte also, unter der Annahme einer qualitativ hochwertigen Wetterprognose, mit diesem Verfahren eine gute Prognose des Wärmebedarfs für die nächsten 24 h möglich sein.

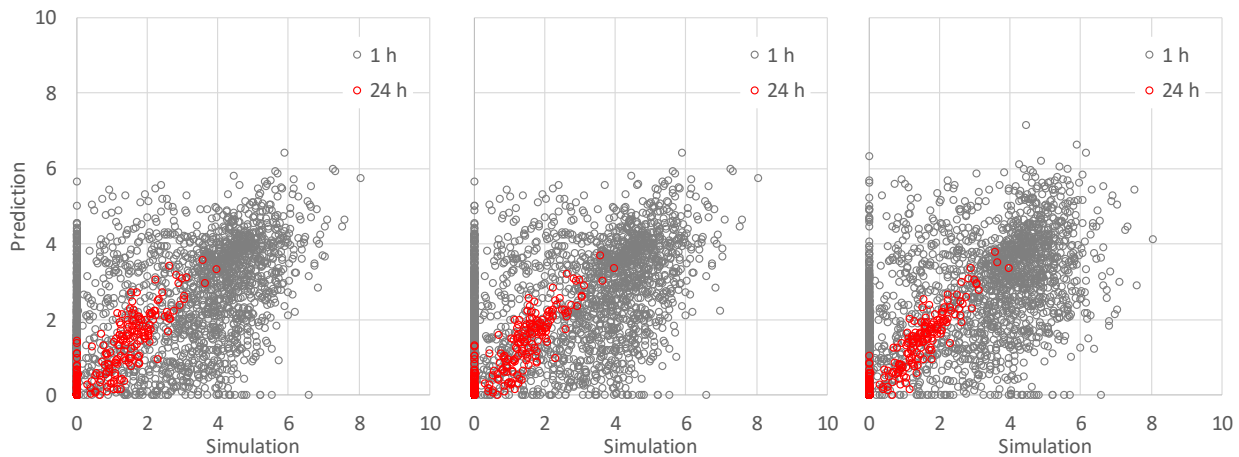


Abbildung 28: Vergleich zwischen Prognose und tatsächlichen Werten (Simulation) für  $\dot{Q}_{SH}$  für die drei beschriebenen Regressionsmodelle; Links: nur  $t_{amb}$ , Mitte:  $t_{amb}$  und  $I_{glob}$ , Rechts:  $t_{amb}$  und  $I_{glob,24h}$ ;

Insgesamt zeigt sich, dass mit diesem vergleichsweise einfachen Verfahren, ähnlich gute Ergebnisse möglich sind, wie mit den neuronalen Netzen (siehe Abschnitte 4.1.1 und 4.1.2). Ein direkter Vergleich der Ergebnisse bzw. Kennzahlen ist allerdings leider nicht möglich, da mit den NN jeweils nur Prognosen für die nächsten 2,5 und 12 h betrachtet wurden.

## 4.1.6 NFM-LoLiMoT Modell

### Trainings-Resultate

Das Verhalten des Wärmespeichers wurde mit einem NFM-LoLiMoT Modell (Abschnitt 3.4.4) abgebildet. Da die Regelung so konzipiert ist, dass es Wettervorhersagen für das Optimierungsproblem berücksichtigt um Energieeinsparungen zu erzielen, wurden mit dem TRNSYS Simulation-Studio verschiedene Datensätze für unterschiedliche Wetterbedingungen erzeugt. Extreme Wetterdatensätze, d.h. für ein kaltes und ein warmes Jahr, wurden als Trainingsdatensätze verwendet, während ein mittlerer Wetter-Datensatz für Validierungszwecke diente. Außerdem wurden verschiedene Datensätze mit unterschiedlichen Sequenzen zum Aktivierungssignal für die Nachheizung erstellt. Damit soll die Bandbreite der vom NFM-LoLiMoT-Modell erfassten Betriebszustände vergrößert werden. Je größer die Bandbreite der Daten, desto besser kann das Modell trainiert werden. Alle diese Datensätze sind in Tabelle 7 angeführt.

Das NFM-LoLiMoT Modell wurde mit den folgenden Parametern trainiert:

- Input-Verzögerungen für die externe Dynamik (autoregressiver Ansatz): 6
- Output-Verzögerungen für die externe Dynamik (autoregressiver Ansatz): 6
- Maximale Anzahl von lokalen linearen Modelle: 40
- Ein Multipler Input - Single Output (MISO) Modell für jeden Temperatursensor:  $T_{s4}$ ,  $T_{s5}$ .

Die Genauigkeit der Trainingsphase für jeden Temperatursensor ist in Tabelle 7 ersichtlich.

Tabelle 7: Performance-Kennzahlen (bezogen auf normierte Werte) für die verschiedenen Datensätze, die für das Training verwendet wurden.

| Datensatz                                | Temp. Sensor | MSE    | MAE    | R <sup>2</sup> |
|--|--------------|--------|--------|----------------|
| Kaltes Wetter, Nachheizung aus           | Ts4          | 0.0033 | 0.0483 | 0.9755         |
| Kaltes Wetter, Nachheizung zeitweise aus | Ts4          | 0.0048 | 0.0542 | 0.9141         |
| Kaltes Wetter, abweichender Sollwert     | Ts4          | 0.0049 | 0.0540 | 0.8520         |
| Kaltes Wetter, normaler Betrieb          | Ts4          | 0.0050 | 0.0545 | 0.8805         |
| Warmes Wetter, Nachheizung aus           | Ts4          | 0.0026 | 0.0413 | 0.9729         |
| Warmes Wetter, Nachheizung zeitweise aus | Ts4          | 0.0039 | 0.0435 | 0.9104         |
| Warmes Wetter, abweichender Sollwert     | Ts4          | 0.0048 | 0.0454 | 0.8109         |
| Warmes Wetter, normaler Betrieb          | Ts4          | 0.0041 | 0.0436 | 0.8719         |
| Mittelwert Ts4                           |              | 0.0042 | 0.0481 | 0.8985         |
| Kaltes Wetter, Nachheizung aus           | Ts5          | 0.0026 | 0.0419 | 0.9807         |
| Kaltes Wetter, Nachheizung zeitweise aus | Ts5          | 0.0247 | 0.1023 | 0.5610         |
| Kaltes Wetter, abweichender Sollwert     | Ts5          | 0.0262 | 0.1071 | 0.2031         |
| Kaltes Wetter, normaler Betrieb          | Ts5          | 0.0251 | 0.1075 | 0.4059         |
| Warmes Wetter, Nachheizung aus           | Ts5          | 0.0034 | 0.0490 | 0.9651         |
| Warmes Wetter, Nachheizung zeitweise aus | Ts5          | 0.0070 | 0.0599 | 0.8378         |
| Warmes Wetter, abweichender Sollwert     | Ts5          | 0.0074 | 0.0598 | 0.7058         |
| Warmes Wetter, normaler Betrieb          | Ts5          | 0.0078 | 0.0618 | 0.7533         |
| Mittelwert Ts5                           |              | 0.0130 | 0.0737 | 0.6766         |

Die Vorhersagen der NFM-LoLiMoT-Modelle (für die Sensoren  $T_{s4}$  und  $T_{s5}$ ) im Vergleich zu den TRNSYS-Simulationsdaten für den Fall mit der besten und der schlechtesten Performance sind in Abbildung 29 abgebildet.

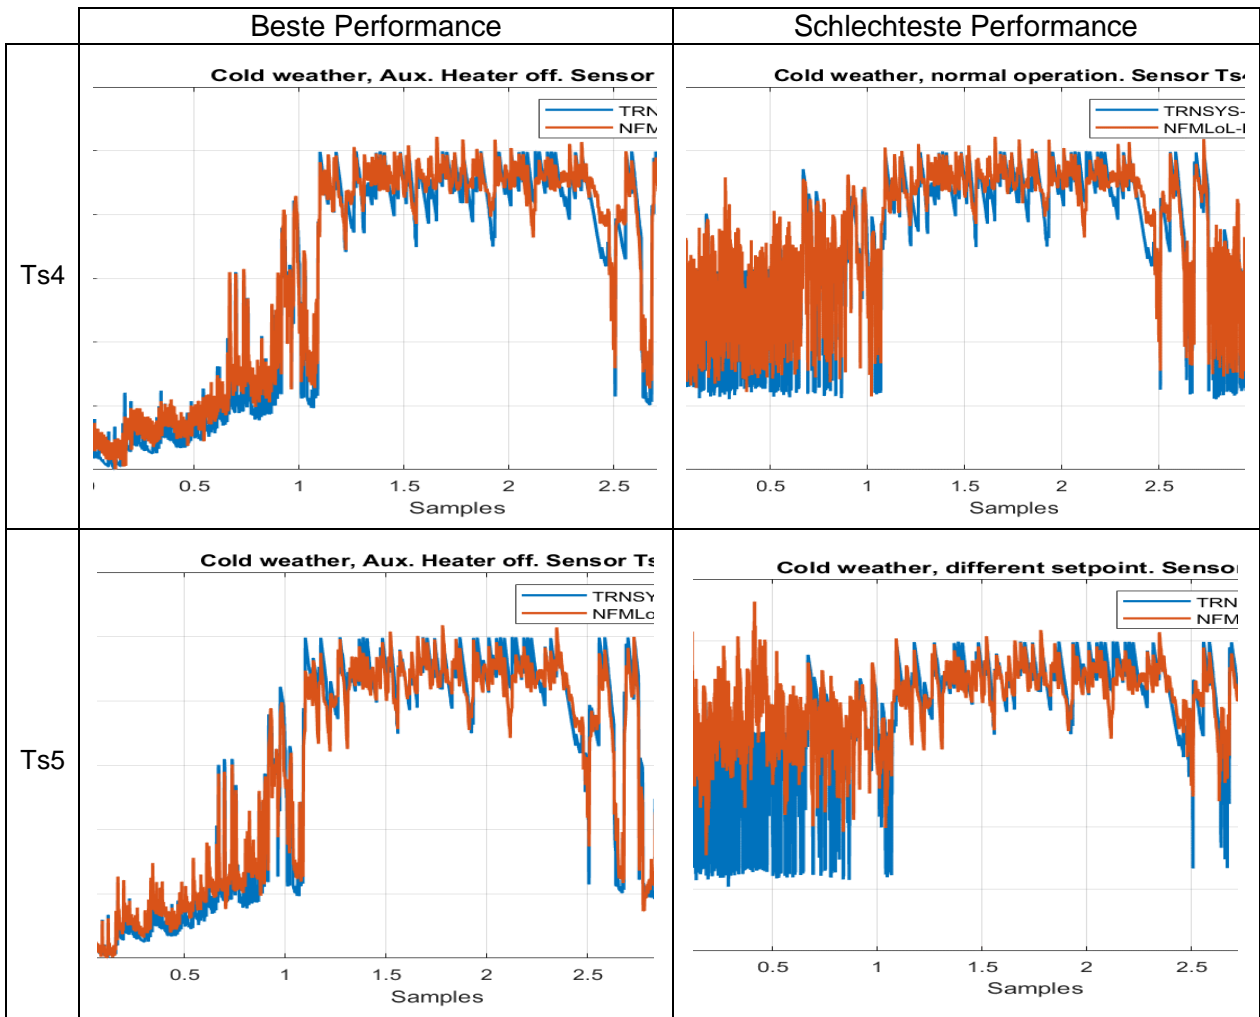


Abbildung 29: Performance des NFM-LoLiMoT-Modells bewertet mit Trainingsdaten

Tabelle 8: Performance-Kennzahlen (bezogen auf normierte Werte) für die verschiedenen Datensätze, die für die Validierung verwendet wurden.

| Datensatz                                   | Temp. Sensor | MSE    | MAE    | R <sup>2</sup> |
|---|--------------|--------|--------|----------------|
| Mittleres Wetter, Nachheizung aus           | Ts4          | 0.0035 | 0.0472 | 0.9704         |
| Mittleres Wetter, Nachheizung zeitweise aus | Ts4          | 0.0046 | 0.0506 | 0.9112         |
| Mittleres Wetter, abweichender Sollwert     | Ts4          | 0.0063 | 0.0559 | 0.7947         |
| Mittleres Wetter, normaler Betrieb          | Ts4          | 0.0049 | 0.0512 | 0.8753         |
| Mittelwert Ts4                              |              | 0.0048 | 0.0512 | 0.8879         |
| Mittleres Wetter, Nachheizung aus           | Ts5          | 0.0038 | 0.0515 | 0.9676         |
| Mittleres Wetter, Nachheizung zeitweise aus | Ts5          | 0.0143 | 0.0827 | 0.7240         |
| Mittleres Wetter, abweichender Sollwert     | Ts5          | 0.0129 | 0.0783 | 0.5812         |
| Mittleres Wetter, normaler Betrieb          | Ts5          | 0.0144 | 0.0826 | 0.6351         |
| Mittelwert Ts5                              |              | 0.0114 | 0.0738 | 0.7270         |

## Validierung

Zur Validierung wurden Klimadatensätze mit einem mittleren Wetter verwendet. Die

Tabelle 8 zeigt die erzielten Genauigkeiten für die  $T_{s4}$  und  $T_{s5}$  NFM-LoLiMoT Modelle.

Die Vorhersagen der NFM-LoLiMoT-Modelle (für  $T_{s4}$ - und  $T_{s5}$ -Sensoren) im Vergleich zu den TRNSYS-Simulationsdaten für den Fall mit der besten und der schlechtesten Performance für die Validierungsdaten (mittleres Wetter) sind in Abbildung 30 dargestellt.

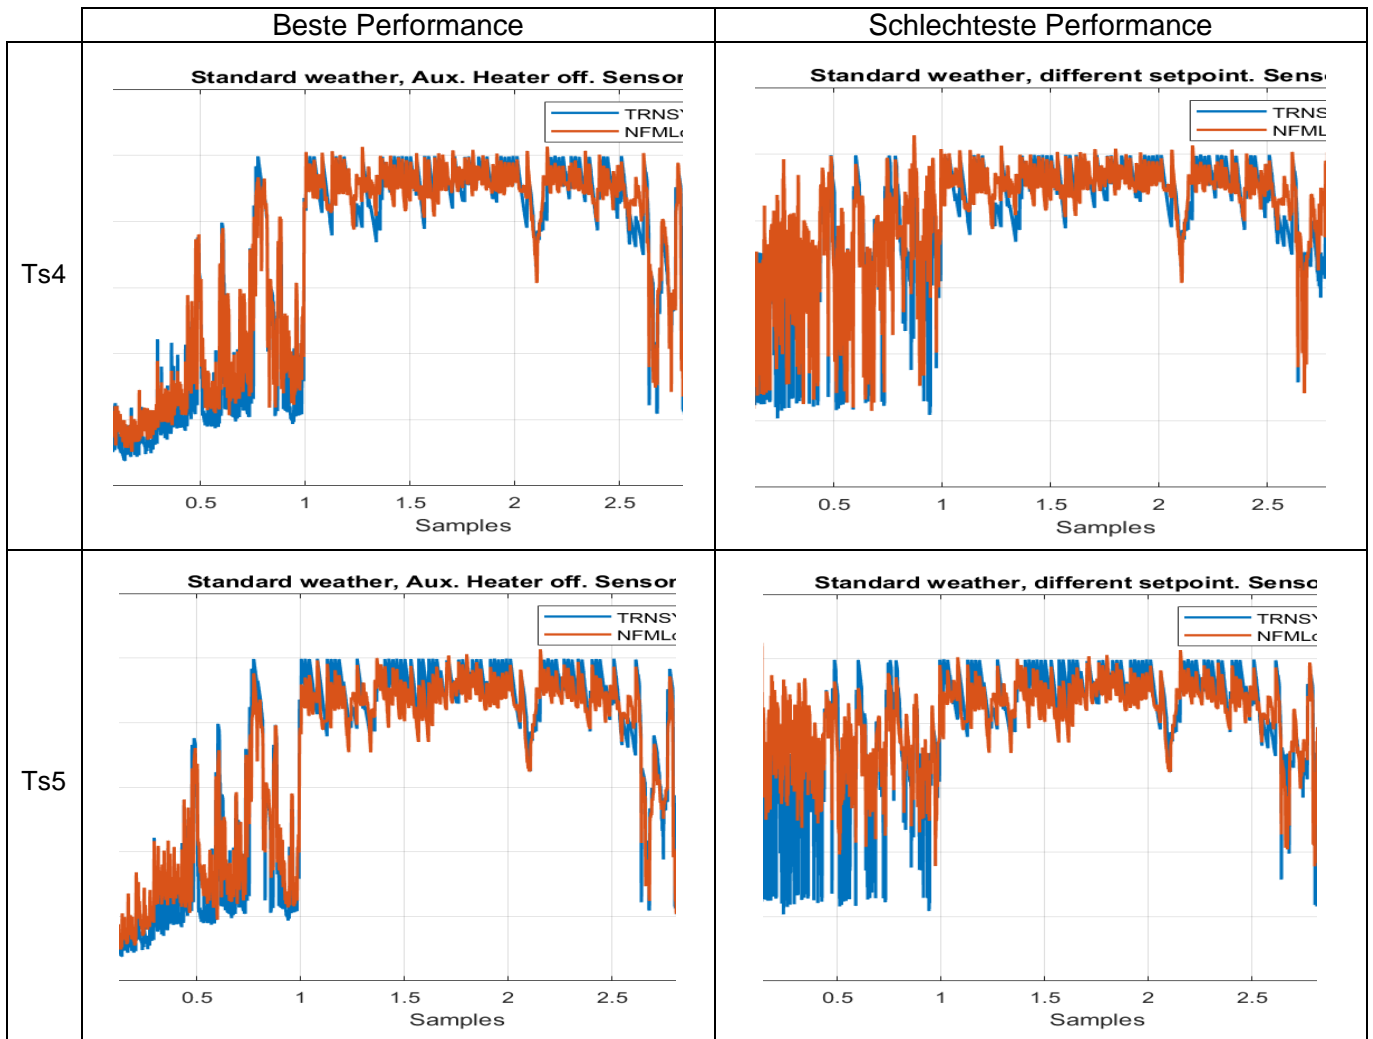


Abbildung 30: Performance des NFM-LoLiMoT-Modells bewertet mit Validierungsdaten

## 4.2 Modellprädiktive Regelung mit KI-basierten Modellen

Für die Simulationen mit dem MPC-Regler wurden die Programme TRNSYS und Matlab mit einem Python-Skript für die KI-Modelle verknüpft. Die numerische Simulation von TRNSYS wird ausgeführt und nach Erreichung der Konvergenz im jeweiligen Zeitschritt wird ein Matlab-Skript aufgerufen. Während dieses Aufrufs werden Daten aus TRNSYS ausgelesen, gemittelt, normalisiert und von den Vorhersage- und Kontrollmodellen verwendet, wie im obigen Abschnitt erläutert.

Die Abbildung 31 zeigt die Vergleichsergebnisse einer einjährigen Simulation, die durchgeführt wurde, um die Performance des neuen Regelungss-Systems zu testen.




Abbildung 31: Ein-Jahres-Simulation mit der MPC-Regelung im Vergleich zur Standard-Hysterese-Regelung des Kombi-Systems. Die Temperaturen in °C der Sensoren  $T_{s5}$  und  $T_{s4}$  sind in den ersten beiden Diagrammen dargestellt, die Aktivierungssignale der Nachheizung (ein/aus) im unteren.

Es wurde eine Integration des Aktivierungssignals der Nachheizung durchgeführt, um einen energieähnlichen Index zu erhalten, der die Verbesserung des Systems aufzeigt. Im Normalbetrieb mit der Standardregelung (Hysterese-Regelung) beträgt das Integral der Aktivierungssignale 12.842. Die MPC-Regelung erreicht ein Integral von 12.550, was einer Verringerung des Energieverbrauchs um 2,3 % entspricht.

In den Diagrammen in Abbildung 32 ist zu erkennen, dass bei vorhergesagter Wärmezufuhr durch den Sonnenkollektor (gelbe Linie im unteren Diagramm) das MPC-Aktivierungssignal (blaue Linie im unteren Diagramm) die Nachheizung nicht aktiviert, während diese bei der Standard-Regelung eingeschaltet wird (rote Linie im unteren Diagramm). Auf diese Weise werden Energieeinsparungen erzielt.

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

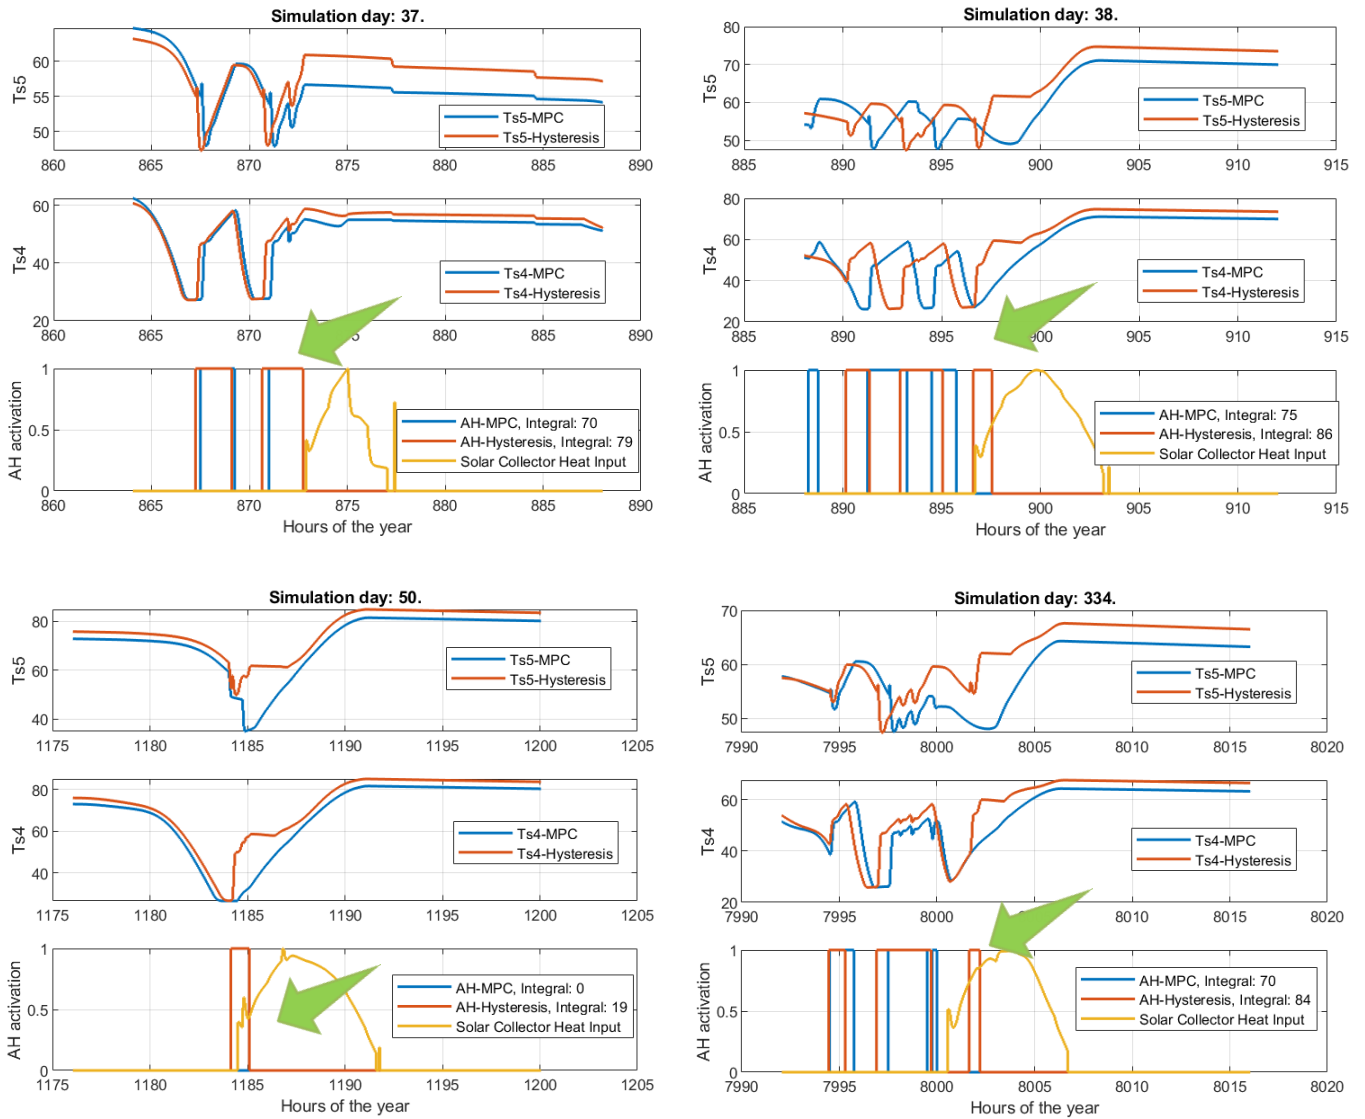


Abbildung 32: Simulationsergebnisse für verschiedene Tage im Jahr, an denen die MPC-Regelung aufgrund der prognostizierten Wärmezufuhr vom Solarkreislauf Energieeinsparungen erzielen kann. Es zeigt sich, dass die MPC-Regelung die Nachheizung früher deaktiviert oder nicht aktiviert, wenn Wärmezufuhr aus dem Solarkreislauf (gelbe Linie) erwartet wird.

## 5 Ausblick und Empfehlungen

Die Abbildung von verschiedenen Teilsystemen des betrachteten Kombisystems durch KI-Modelle wie CNN, LSTM, NFM-LoLiMoT und lineare Regression konnte mit einer recht guten Genauigkeit umgesetzt werden. Die erstellten datenbasierten Modelle wurden erfolgreich in eine modellprädiktive Regelung des Systems eingebunden. Durch diese Regelung und Berücksichtigung verfügbarer Wettervorhersagen konnte in der Simulation eine Optimierung des Energieverbrauchs für die Nachheizung mit Einsparungen von etwa 2,3 % erreicht werden.

Für zukünftige Arbeiten und bessere zu erwartende Energieeinsparungen werden die folgenden Punkte empfohlen:

- In diesem Projekt wurde nur einer der drei Hysterese-Regelkreise im solaren Kombisystem durch den MPC ersetzt. Für ein größeres Potenzial an Energieeinsparungen sollte die Substitution der Hysterese-Regelung durch MPC in allen Regelkreisen des Systems in Betracht gezogen werden.
- Die Durchführung einer TRNSYS-Matlab-Python-Simulation war recht ineffizient und zeitaufwändig. Um den maximalen Nutzen aus der modellprädiktiven Regelung zu ziehen, sollte eine effizientere Simulations-Lösung gefunden werden.
- Die Kostenfunktion der MPC in Bezug auf die prädizierten Fehler zwischen Wunsch- und Ausgangsgrößen sowie der Stellgröße entworfen und iterativ angepasst. Für eine bessere Interpretierbarkeit und realistischere Szenarien sollte der Entwurf mit Indikatoren für die Wirtschaftlichkeit und den Benutzerkomfort erfolgen, anstatt nur Performance-Gewichtungen zu berücksichtigen.
- Auf der Grundlage der in diesem Projekt trainierten Modelle können verschiedene MPC-Konfigurationen entwickelt werden, um die Möglichkeit besserer Energieeinsparungen zu untersuchen.

Die im Projekt getesteten datenbasierten Modellansätze werden auch in zukünftigen Projekten am IWT zum Einsatz kommen. Einfache Prognose-Methoden für z.B. den Solarertrag oder die benötigte Heizleistung, die anhand von in guter Qualität verfügbarer Wettervorhersagen und von historischen Anlagendaten erstellt werden können, bieten eine effiziente und effektive Alternative zu physikalischen Modellansätzen. Im Projekt konnte dazu Know-How aufgebaut und erste Erfolg versprechende Ansätze getestet werden. Diese können nicht nur als Basis für MPC-Regelungen dienen, sondern auch für weniger komplexe, Regel-basierte Regelungsansätze verwendet werden.

Hinsichtlich der Nutzung von neuronalen Netzen für die CFD-Simulation von Verbrennungsvorgängen waren die Arbeiten in diesem Projekt sehr hilfreich und die erste Nutzung der neuronalen Netze in CFD-Simulationen zeigten großes Potential. Eine Vorstudie von Prieler et al. zeigte eine Beschleunigung der Simulation um den Faktor 4800 bei laminaren Flammen. Durch die beschleunigten CFD-Simulationen sollen in Zukunft große Öfen schneller und effizienter hinsichtlich Energieeinsparung (vor allem in energieintensiven Prozessen der Stahl-, Glas- oder Zementindustrie) optimiert werden und somit zu einem besseren CO<sub>2</sub>-Fußabdruck und Herstellung von „grünem“ Stahl führen. Eine Weiterführung dieser Aktivitäten ist am IWT auf jeden Fall geplant.

## 6 Literaturverzeichnis

Bertsch, F., Fumey, B., Heimrath, R., Dröscher, A., Schranzhofer, H., 2013: 'Deliverable 2.1 - Description of the boundary conditions for each storage technology and of the models for the reference systems', Deliverable 2.1 of the European project COMTES

Haller, M.Y., 2007. Type 805: DHW heat exchanger, Version 1.1. SPF Institute for Solar Technology, Rapperswil CH.

Hartmann B., Ebert T., Fischer T., Belz J., Kampmann G., Nelles O., 2012: "LMNtool - Toolbox zum automatischen Trainieren lokaler Modellnetze", 22. Workshop Computational Intelligence, Dortmund, Dezember 2012.

Heimrath, R., Haller, M., 2007: 'The Reference Heating System, the Template Solar System of Task 32'. Accessed: Aug. 10, 2020. [Online]. Available: [https://www.iea-shc.org/data/sites/1/publications/task32-Reference\\_Heating\\_System.pdf](https://www.iea-shc.org/data/sites/1/publications/task32-Reference_Heating_System.pdf)

Holst S., 1996. TRNSYS-models for Radiator Heating Systems; Dynamic Radiator Model with Pipes (Type 162). [https://trnsys.de/static/641c965bac4f593c3b4cc569839a51c2/Type\\_361\\_362\\_320\\_en.pdf](https://trnsys.de/static/641c965bac4f593c3b4cc569839a51c2/Type_361_362_320_en.pdf) (accessed 3 November 2020).

Hou, Z.-S., Wang, Z., 2013: From model-based control to data-driven control: Survey, classification and perspective, Information Sciences 235 (2013) 3–35.

Jordan, U., Vajen, K., 2012. DHWcalc - Tool for the Generation of Domestic Hot Water (DHW) Profiles on a Statistical Basis. Universität Kassel, Institut für Thermische Energietechnik.

Meteotest, 2020: Meteororm v8.0.4.2199, Global Meteorological Database for Engineers, Planner and Education. Meteotest AG, Bern, Switzerland.

Nelles, O., 2001: Nonlinear system identification., Springer Berlin Heidelberg; doi:<https://doi.org/10.1007/978-3-662-04323-3>.

Nigitz, T., Gölles, M., 2019. A generally applicable, simple and adaptive forecasting method for the short-term heat load of consumers. Applied Energy 241, 73–81. <https://doi.org/10.1016/j.apenergy.2019.03.012>

Rawlings, J. B., Mayne, D. Q., 2015: Model Predictive Control: Theory and Design, Nob Hill Publishing

Rehrl, J., Kirchengast, M., Celikovic, S., Sacher, S., Krusz, J., Khinast, J., Horn, M., 2019: Improving Pellet Quality in a Pharmaceutical Hot Melt Extrusion Process via PID Control and LOLIMOT-Based

MPC, Journal of Pharmaceutical Innovation (dec 2019). doi:10.1007/s12247-019-09417-0.URL  
<http://link.springer.com/10.1007/s12247-019-09417-0>

Rehrl, J., Schwingshackl, D., Horn, M., 2014: A modeling approach for hvac systems based on the lolimot algorithm, IFAC Proceedings Volumes 47 (3) (2014) 10862–10868.

Schwingshackl, D., Rehrl, J., Horn, M., 2016: Lolimot based mpc for air handling units in HVAC systems, Building and environment 96 (2016) 250–259.

## 7 Anhang: Tabelle mit Ergebnissen der Literaturrecherche

| Autoren         | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung  | Stand der Technik   | Vergleichsmethode  | Ergebnisse   |
|-----------------|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|--|---|--|--|
| Korthals et al. | Industry         | Artificial Intelligence in predictive thermal management for passenger cars                                 | 2020 | LSTM ANN               | X                    | X         |                | X                      | X                                      | X                 | optimal engine temperature for all driving states, ANN usage to reduce effort of manual parameter calibration because of changes in hard/software user behaviour                               | individually controlled electrical devices (pumps, fans, air panels, valves), controlled by characteristic curves and maps, 5000+ parameters which have to be calibrated manually | ANN model predictions were compared to measurement data from test runs | working ANN models that can replace physical models in MPC   |
| Liao et al.     | Industry         | Modeling of Reheating-Furnace Dynamics Using Neural Network Based on Improved Sequential-Learning Algorithm | 2006 | RBF NN                 | X                    |           |                |                        |  | X                 | In order to model the dynamics of a billet reheating furnace, a multi-input multi-output radial-basisfunction neural network is constructed based on an improved sequential-learning algorithm | mostly physical models which only consider major effects, like heat exchange through radiation  | verification tests based on actual runs                                | This NN reheating-furnace model was employed for the immune-based optimal control of furnace temperature, and the results were found to be superior to those obtained by conventional models |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren       | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung  | Stand der Technik   | Vergleichsmethode  | Ergebnisse   |
|---------------|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|--|---|--|--|
| Matino et al. | Industry         | Forecasting blast furnace gas production and demand through echo state neural network-based models: Pave the way to off-gas optimized management | 2019 | ESN                    |                      |           |                | X                      |  |                   | Forecasting blast furnace gas volume flowrate and heating power by ESN, Prediction of blast furnace gas demand by hot blast stoves through ESNs avoiding losses of a valuable secondary resource and related emissions | off gases are collected and used e.g. for heating scrap, but often flamed in case of overproduction | models have been off-line trained and tested by exploiting real data, which have been provided by the facilities and are related to 6 months of production | allow a continuous optimal planning of the blast furnace gas usage according to its availability and to the needs in the steelworks, by avoiding losses of a valuable secondary resource and related emissions.<br><br>Forecast error between 1.6 and 6.9% in a time horizon of 2h |
| Wang et al.   | Industry         | Furnace thermal efficiency modeling using an improved convolution neural network based on parameter-adaptive mnemonic enhancement optimization   | 2019 | AMEO CNN               | X                    | X         |                | X                      |  |                   | model for furnace thermal efficiency   | for thermal efficiency: physical models, data driven modelling, sometimes both combined             | comparison of the AMEO-CNN method to other NN methods  | simulation results show that AMEO CNN model can be used as an accurate model for helping to find the way to optimizing and improving the thermal efficiency, higher accuracy compared to other NN  |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren              | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik   | Vergleichsmethode   | Ergebnisse   |
|----------------------|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|---|---|--|
| Kocyigit             | Industry         | Fault and sensor error diagnostic strategies for a vapor compression refrigeration system by using fuzzy inference systems and artificial neural network | 2015 | FIS, ANN               |                      |           |                |                        | X                                      |                   | usage of FIS and ANN for detecting faults which leads to reduced energy consumption/cost                              | steady state model based algorithms as well as NN/fuzzy model approaches          | fault estimation error of the FIS and ANN were evaluated by using the experimentally obtained sensor data | Performance of the tested systems verified that the proposed fault diagnostic FIS and the ANN had an ability to diagnose eight faults in the basic refrigeration system. Moreover the proposed error prognostic fuzzy inference system had also ability to detect error of one or two sensors. The FIS and ANN based diagnostic systems effectively detected the problems and classified the faults in the study. These approaches eliminated the need of extensive modeling for the use of analytic models. |
| Nguyen et al.        | Industry         | Neural Network based Model Reference Control for Electric Heating Furnace with Input Saturation  | 2019 | RNN                    | X                    |           |                |                        |  | X                 | RNN to model electric heating furnace, an other RNN for control   | PID and MPC controllers   | simulation based comparison of MPC, PID and ANN controllers   | good (same) performance in comparison with the PI and MPC controllers, can deal with the input constraint of the plant   |
| Radhakrishnan et al. | Industry         | Neural networks for the identification and control of blast furnace hot metal quality  | 2000 | NN                     | X                    |           |                |                        | X                                      |                   | development of a soft sensor, based on NN, for the prediction of silicon and sulfur % in the composition of hot metal | taking and analyzing probes, nowadays probably various kinds of predictive models | predicted output parameters were compared with measured values  | model could be effectively used for online control of Si and S in the hot metal, accuracy better than 3%   |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren           | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik | Vergleichsmethode  | Ergebnisse   |
|-------------------|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|-------------------|--|--|
| Zhong et al. 2017 | Building         | Development of a Data-Driven Approach for Human-Based Environmental Control            | 2017 | ANN                    | X                    |           |                | X                      |  | X                 | apply AI algorithm for thermal comfort control  | PMV model         | Subjects (persons) were asked to participate in the validation experiments, and results of the experiment were used to analyze the performance of the ANN model by using the 10-fold cross validation method | A total of up to 45% more energy savings and 44.3% better thermal comfort performance than the PMV model                                       |
| Zhao et al. 2020  | Building         | Intelligent Thermal Comfort Controlling System for Buildings Based on IoT and AI       | 2020 | ANN                    | X                    |           |                | X                      |  | X                 | intelligent thermal comfort control system based on the Internet of Things and intelligent artificial intelligence                                  |                   |  | The system performed better than traditional control on comfort and energy savings. Limitations: ~3% error between expected and actual values. |
| Hua Han et al.    | Industry         | Novel chiller fault diagnosis using deep neural network (DNN) with simulated annealing | 2020 | (SA-)-DNN              | X                    |           |                |                        | X                                      |                   | develop a novel fault diagnosis strategy for a chiller, which merges simulated annealing (SA) into a deep neural network (DNN) to obtain effective, |                   | data generated from physical chiller used to train SA-DNN, data also to test the generated   | overall diagnostic of SA-DNN accuracy achieves 99.30% for the eight categories, including normal operation and seven typical faults            |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren              | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung  | Stand der Technik | Vergleichsmethode  | Ergebnisse  |
|----------------------|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|--|-------------------|--|---|
|                      |                  |  |      |                        |                      |           |                |                        |  |                   | efficient, and stable performance.   |                   | model<br>results were also compared to other NN approaches |   |
| Vasickaninová et al. | Industry         | Neural network predictive control of a heat exchanger                            | 2011 | ANN                    | X                    | X         |                |                        |  | X                 | show that using the neural network predictive control can lead to energy savings by modelling and controlling heat exchanger with ANN  | PID controllers   | simulation experiments                                     | simulation results confirm that NNPC as a not linear-model-based strategy is a good tool for successful control of heat exchangers (less oscillating, constraints included) |
| Nowak et al.         | Industry         | Using the artificial neural network to control the steam turbine heating process | 2016 | ANN                    | X                    |           |                | X                      |  | X                 | create a predictive model for the steam turbine operation control based on the ANN<br><br>ANN: rotor speed, steam pressure, temperatures --> stresses<br><br>create algorithm how to control steam inlet temperature |                   | simulation;<br>comparison to FEM results                   | results with an error of about 20%<br><br>Two serial neural networks made it possible to model the rotor stress based of steam parameters.                                  |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren            | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools                   | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung  | Stand der Technik                  | Vergleichsmethode                                | Ergebnisse  |
|--------------------|------------------|---|------|--|----------------------|-----------|----------------|------------------------|--|-------------------|--|------------------------------------|--|---|
| Alotaibi           | Industry         | Prediction of the Minimum Film Boiling Temperature of Quenching Vertical Rods in Water Using Random Forest Machine Learning Algorithm | 2021 | Random Forest Machine Learning Algorithm | X                    |           |                |                        |  |                   | apply machine learning algorithm to predict film boiling temperature   | correlation models from literature | comparison to correlation models from literature | maximum forecast deviation of 13,6%   |
| Amin               | Industry         | Intelligent fault diagnosis of cooling radiator based on deep learning analysis of infrared thermal images                            | 2019 | ANN                                      |                      |           |                |                        | X                                      |                   | fault diagnosis of radiator  | experience based?                  | -  | Classification accuracy of fault detection is 96.67%.   |
| ZequnWang, Yuxiang | Building         | Data-driven modeling of building thermal dynamics: Methodology and state of the art   | 2019 | AI,TF,RC                                 | X                    |           |                | X                      |  |                   | Data-driven modeling to illustrate a case study of a single zone house. A RC , an ARX and ANN are developed to predict the indoor air temperature. |                                    |  | all models exhibit favourable prediction ability, ANN is better than RC or ARX , ARX model is trained by linear least squares |
| Moon, Jim Woo      | Building         | Performance of ANN-based predictive and adaptive thermal-control methods for disturbances in and around residential buildings         | 2012 | ANN                                      | X                    | X         |                | X                      |  | X                 | to develop the ANN based residential thermal-control logics and test their performance and adaptability.   |                                    | ANN based and non ANN based                      | ANN works properly for predicting $\Delta$ Temperature and $\Delta$ PMV but occurs errors for predicting $\Delta$ Humidity    |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren  | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik | Vergleichsmethode | Ergebnisse   |
|--|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|-------------------|-------------------|--|
| Moon, Jim<br>Woo   | Building         | ANN-based thermal control models for residential buildings  | 2010 | ANN                    | X                    | X         | X              | X                      |  |                   | to develop an ANN based advanced thermal control methode in residential buildings   |                   |                   | ANN-based predictive control logic for controlling showed high accuracy, PCL employing ANN reduced the magnitudes of overshoots of thermal conditions  |
| Ciulla, G.;<br>D'Amico, A.; Lo<br>Brano, V.;<br>Traverso, M. | Building         | Application of optimized artificial intelligence algorithm to evaluate the heating energy demand of non-residential buildings at European level | 2019 | ANN                    | X                    | X         | X              | X                      |  |                   | how to predict the energy demand with ANN in Europe   |                   |                   | they found an ANN to determine the heating energy demand , qick and simple, 12 well-known themo-physical parameters without knowledge of the thermal balance   |
| Yang, In-Ho;<br>Yeo, Myoung-<br>Souk; Kim,<br>Kwang-Woo      | Building         | Application of artificial neural network to predict theoptimal start time for heating system in buildin   | 2003 | ANN                    | X                    | X         |                | X                      |  |                   | The objective of this study is to develop an optimized ANN model to determine the optimal starttime for a heating system in a building                                    |                   |                   | the optimized ANN was shown to be capable of determining the start time accurately   |
| Byeongmo Seo   | Building         | ANN-Based Thermal Load Prediction Approach for Advanced Controls in Building Energy Systems   | 2019 | ANN                    | X                    | X         | X              | X                      |  | X                 | ANN model was developed to predict a large office building's cooling loads , focus on explaining the general procedure of developing the ANN-based load predicting models |                   |                   | The results of the example study showed that the ANN technology has a large potential for energy savings as ANN models can be developed for the optimal control of building energy systems that require thermal loads to be able to provide the necessary energy to spaces |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren      | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik | Vergleichsmethode | Ergebnisse  |
|--------------|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|-------------------|-------------------|---|
|              |                  |  |      |                        |                      |           |                |                        |  |                   | for the future use of optimal control of building energy systems  |                   |                   |   |
| Boje, Edward | Building         | Neural Network based HVAC Predictive Control | 2014 | ANN                    | X                    | X         | X              | X                      |  | X                 | his paper addresses the problem of controlling Heating Ventilation and Air Conditioning (HVAC) systems with the purpose of maintaining a desired thermal comfort level, whilst minimizing the electrical energy required. |                   |                   | A MBPC control methodology using neuronal networks to control existing HVAC systems in buildings turned out to be robust and able to obtain energy savings typically greater than 50% under normal building occupation. |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren  | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik | Vergleichsmethode     | Ergebnisse  |
|--|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|-------------------|-----------------------|---|
| Bui, Dac-Khuong;<br>Nguyen, Tuan Ngoc; Ngo, Tuan Duc;<br>Nguyen-Xuan, H.   | Building         | An artificial neural network (ANN) expert system enhanced with the electromagnetism-based firefly algorithm (EFA) for predicting the energy consumption in buildings | 2020 | ANN                    | X                    | X         |                | X                      |  |                   | a hybrid model, the EFA-ANN, is proposed to forecast the energy consumption in buildings. The model is applied to evaluate the (HL) and (CL) using two given datasets. Each dataset was obtained by monitoring the effect of the façade system and dimensions the building, respectively, on energy consumption |                   | ELM and EFA-ANN       | EFA-ANN is 5 times faster than the ELM method and 7 times faster than GP in terms of computing time, EFA ANN can help building engineers to design energy efficient buildings                 |
| Hussain, Muhammed;<br>Dhimish, Mahmoud;<br>Titarenko, Sofya; Mather, Peter | Building         | Artificial neural network based photovoltaic fault detection algorithm integrating two bi-directional input parameters   | 2020 | ANN                    | X                    | X         |                | X                      | X                                      | X                 | a fault detection algorithm for PV systems based on ANN is proposed. The paper shows the successful development, deployment and validation of a fault detection PV system using radial basis function (RB), requiring two parameters  |                   | different ANN methods | the ANN accuracy increased up to 98.1% based on the implementation of the fourth methodology consisting of data normalisation as well as mapping of solar irradiance against output PV power. |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren        | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik  | Vergleichsmethode                        | Ergebnisse  |
|----------------|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|--|--|---|
| Wang, Hong Tao | Building         | Typical Building Thermal and Thermal Load Forecasting Based on Wavelet Neural Network                               | 2020 | WPNN                   | X                    | X         |                | X                      |  |                   | Based on the historical data of the cold/heat/electrical load of five typical buildings, the wavelet neural network is used for cold/heat/electrical short-term load forecasting. . cold/heat/electrical short-term load forecasting. . | the methods for predicting the load of typical buildings include simulation methods based on building energy analysis software , these are only applicable during the building planning and design phase. These predictions load have uncertainties, which leads to errors | simulation methodes                      | WPNN has high prediction in accuracy , the calculation speed is fast , it has high prediction accuracy for short-term load of cold/heat/electrical load . |
| Ammar et al.   | Building         | Photovoltaic power forecast using empirical models and artificial intelligence approaches for water pumping systems | 2020 | FFNN, ANFIS            | X                    | X         |                | X                      | X                                      |                   | PV power forecast though ambient tempature and solar irradiation estimation. Three methodes were compared.  |  | Physical models, feed forward ANN, ANFIS | FFNN and ANFIS technologies showed high prediciton accuracy in ambient temperature and solar irradiation  |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren            | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik | Vergleichsmethode | Ergebnisse  |
|--------------------|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|-------------------|-------------------|---|
| Cuilla et al.      | Building         | Application of optimized artificial intelligence algorithm to evaluate the heating energy demand of non-residential buildings at European level | 2019 | ANN                    | X                    | X         |                | X                      | X                                      |                   | Alternative method to solve the building energy balance without any computational cost.<br>-Development of an ANN to assess of the energy performance of non residential building.<br>-Several dynamic models in different location ( in trnsys)<br>-Implementation and creation of an organized energy database set. |                   |                   | The authors could identify the best ANN developing a tool for determining quickly and simply the heating energy demand of non residential buildings knowing only 12 thermo physical parameters without any computational cost or knowledge about the thermal balance. ( Reliability also showed by low standard deviation less than 5kWh/(m <sup>2</sup> *year) ) |
| Deb, Chirag et al. | Building         | Using artificial neural networks to assess HVAC related energy saving in retrofitted office buildings   | 2018 | MLR/ANN                | X                    | X         |                | X                      | X                                      |                   | Study aims to develop prediction models ( ANN and MLR ) for HVAC related energy saving in office buildings, the essence of this study is to find the most appropriate input variables forms.  |                   | MLR/ANN           | The results show that the ANN model is more accurate with a mean absolute percentage error (MAPE) of 14.8%. The best combination of variables to achieve this comprises of gross floor area (GFA), air-conditioning energy consumption, operational hours and chiller plant efficiency.   |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren       | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik | Vergleichsmethode               | Ergebnisse   |
|---------------|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|-------------------|---------------------------------|--|
| Kumar et al.  | Building         | Artificial intelligence based forecast models for predicting solar power generation | 2018 | ANN/AN FIS             | X                    | X         |                |                        | X                                      |                   | ANN and ANFIS based forecast models for prediction the PV Generation are represented. results of the proposed models are validated and compared by a data set of a PV power generation station.   |                   | ANN/ANFIS                       | The ANN based forecast delivers better results when compared to the ANFIS based forecast           |
| Sharma et al. | Building         | Short term solar irradiance forecasting using a mixed wavelet neural network        | 2016 | WNN/ANN                | X                    | X         |                | X                      |  |                   | A mixed WNN is proposed to forecast the short term solar irradiance. In WNN, a combination of the Morley and Mexican hat wavelets is used as the activation function for hidden-layer neurons of a feed forward artificial neural network (ANN) |                   | ARIMA, ETS, Persistence and ANN | The WNN has the best results ins all performance metrics compared to the ETS, persistence and ANN. |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren             | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung  | Stand der Technik | Vergleichsmethode                        | Ergebnisse   |
|---------------------|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|--|-------------------|--|--|
| Amarasinghe, et al. | Building         | Artificial neural networks based thermal energy storage control for buildings            | 2015 | ANN/PD                 | X                    |           |                | X                      | X                                      | X                 | A novel control framework based on (ANN) for optimally controlling a TES for achieving increased savings is presented. ANN utilizes 3 main inputs: 1) current TES energy availability, 2) predicted building power requirement, and 3) predicted utility load/price  |                   | ANN control framework with PD controller | After comparing ANN and PD in several test cases it showed that ANN outperformed the classical PD in all cases   |
| Baris et al.        | Building         | ANN-GA smart appliance scheduling for optimized energy management in the domestic sector | 2016 | ANN                    | X                    | X         |                | X                      | X                                      | X                 | The paper presents an (ANN-GA) smart appliance scheduling approach for optimized energy management in the domestic sector. The proposed approach reduces energy demand in "peak" periods, maximizes use of renewable sources while reducing reliance on grid energy. |                   |  | The ANN techniques involve a holistic understanding of (near) real-time energy demand and supply within a domestic context to deliver optimized energy usage with minimum computational needs. The solution is stress-tested and demonstrated in a four bedroom house with grid energy usage reduction by 10%, 25%, and 40%, respectively. |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren       | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik                       | Vergleichsmethode  | Ergebnisse   |
|---------------|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|---|--|--|
| Tan et al.    | Industry         | Artificial neural network modelling of the thermal performance of a compact heat exchanger                | 2009 | SOM ANN                | X                    |           |                |                        | X                                      |                   | Use ANN model to predict heat transfer rate of a heat exchanger; also to classify deterioration (different levels of inlet obstruction)   | non linear regression model             | ANN performance compared to nonlinear regression model and test data | better performance of ANN compared to nonlinear regression model (coefficients obtained with genetic algorithm); only 4 out of 359 results exceed 5% error margin; performance of  |
| Yilmaz et al. | Industry         | Modeling of a mechanical cooling system with variable cooling capacity by using artificial neural network | 2007 | ANN                    | X                    |           |                |                        |  |                   | Model system performance with ANN; 7 out of 10 experiments for training, 3 for testing  | intermittent operation (2 punkt Regler) | Taining and comparison of ANN to experimental results                | Usability of ANN in this area was shown; verage relative errors of the test of artificial neural network were found as; 1.37% for input power, 4.44% for heating power, 2.05% for heating COP, and 1.95% for cooling COP |
| Lissa et al.  | Building         | Deep reinforcement learning for home energy management system control                                     | 2020 | DRL (ANN)              | X                    | X         | X              | X                      | X                                      | X                 | developing artificial-intelligence-(AI)-theory-based optimal control algorithms for improving the indoor temperature conditions and heating energy efficiency of the double-skin buildings. | rule based algorithm                    |  | DRL al- gorithm combined with the dynamic setpoint achieved on average 8% of energy savings compared to a rule-based algorithm the renewable energy consumption is 9.5% higher for the DRL-based model                   |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren          | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik | Vergleichsmethode | Ergebnisse   |
|------------------|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|-------------------|-------------------|--|
| Ma et al.        | Building         | A Building Information Model (BIM) and Artificial Neural Network (ANN) Based System for Personal Thermal Comfort Evaluation and Energy Efficient Design of Interior Space | 2019 | ANN                    | X                    |           | X              |                        | X                                      |                   | the problem that is tried to be solved is the improvement of the energy saving efficiency under the premise of increasing human comfort . The ANN predictive model considering the PMV index the persons position and an innovative plugin of the BIM to realize dynamic evaluation and efficiency. | ANN               | ANN and PMV       | When human body position changes are considered when ist about thermal comfort the ANN model has a higher accuracy than the traditional PMV model in predicting individual thermal comfort.  |
| Chaudhuri et al. | Building         | A feedforward neural network based indoor-climate control framework for thermal comfort and energy saving in buildings  | 2019 | ANN                    | X                    | X         | X              | X                      | X                                      |                   | A new climate control framework for thermal comfort with minimum energy consumption. NN models ACMV energy with air temperature and operating frequencies. Thermal comfort prediction improves building climate control and energy efficiency..   | ANN               |                   | The proposed framework exhibits an energy saving potential of 36.5% . The study shows the potentail to achieve occupant-comfort and energy saving through integration with the IOT things for realizing comfort-energy balanced buildings. |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren         | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung  | Stand der Technik | Vergleichsmethode          | Ergebnisse   |
|-----------------|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|--|-------------------|----------------------------|--|
| Deb et al.      | Building         | Forecasting diurnal cooling energy load for institutional buildings using Artificial Neural Networks                         | 2016 | ANN                    | X                    |           |                | X                      | X                                      |                   | A methodology to accurately forecast diurnal cooling load for institutional buildings is presented.  | ANN               |                            | A new method is presented to develop a forecasting models while dealing with highly variable energy consumption data of institutional buildings. This study shows that it is possible to predict many days in succession without changing any of the model parameters. |
| Ashtiani et al. | Building         | Indoor thermal condition in urban heat island: Comparison of the artificial neural network and regression methods prediction | 2014 | ANN                    | X                    |           | X              | X                      | X                                      | X                 | Cities should be empowered with predictive tools during extreme heat waves in order to be able to provide emergency plans. As a reliable warning system ANN and regressions method were proposed and tested for an indoor air temperature forecasting application with respect to neighborhood parameters. | ANN               | ANN and regressions models | The ANN model showed better accuracy in predicting the indoor dry-bulb temperature but it was more compicated to implement.  |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren           | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung  | Stand der Technik | Vergleichsmethode | Ergebnisse  |
|-------------------|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|--|-------------------|-------------------|---|
| In-Ho Yang et al. | Building         | Application of artificial neural network to predict the optimal start time for heating system in building | 2003 | ANN                    | X                    | X         |                | X                      | X                                      | X                 | The purpose of this study is to develop and ANN model to determine the optimal start time for a heating system in a building. For this, programs for predicting the room air temperature and the learning of the ANN model based on back propagation learning were developed, and learning data for various building conditions were collected through program simulation for predicting the room air temperature using systems of experimental design | ANN               |                   | The optimized ANN was shown to be capable of determining the start time accurately. |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren               | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung  | Stand der Technik      | Vergleichsmethode                                | Ergebnisse  |
|-----------------------|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|--|------------------------|--|---|
| Hernandez Neto et al. | Building         | Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption | 2008 | ANN                    | X                    |           |                | X                      |  |                   | In this paper, a comparison is made between a simple model based on artificial neural network (ANN) and a model that is based on physical principles (EnergyPlus) as an auditing and predicting tool in order to forecast building energy consumption. | ANN, Simulation models | ANN , model that is based on physical principles | Both models are suitable for energy consumption. The ANN model is only capable of predicting the energy consumption based on previous measurements.   |
| Jorjeta G. Jetcheva   | Building         | Neural network model ensembles for building-level electricity load forecasts   | 2014 | ANN                    | X                    | X         |                | X                      | X                                      |                   | A novel building-level neural network-based ensemble model for day-ahead electricity load forecasting is presented.  | ANN                    | ANN and SARIMA                                   | The ANN based model outperforms the previously established best performing model, SARIMA, by up to 50% in the context of load data from half a dozen operational commercial and industrial sites. |
| Radiša Ž.Jovanović    | Building         | Ensemble of various neural networks for prediction of heating energy consumption                                       | 2015 | FFNN, RBFN, ANFIS      | X                    |           |                | X                      |  |                   | In this paper various artificial neural networks are used to predict the heating energy consumption of a university campus. For each NN type three models  |                        | ANFIS, FFNN, RBFN                                | All models showed a high accuracy. The ensemble by combining the outputs of member networks achieve better prediction results.  |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren             | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung  | Stand der Technik | Vergleichsmethode          | Ergebnisse   |
|---------------------|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|--|-------------------|----------------------------|--|
| Zhipeng Deng et al. | Building         | Simulating the impact of occupant behavior on energy use of HVAC systems by implementing a behavioral artificial neural network mod | 2019 | ANN                    | X                    | X         |                |                        |  | X                 | This paper tries to solve the problem that current methods for simulate building energ consumption are often not accurate due to occupant behavior. A behavioral ANN model was implemented in the energy simulation. |                   | ANN and Simulation program | The simulated results were validated by comparing them with measured data in the HLAB building for a one month period and the relative error was less than 13 %. |
| Golgiyaz et al.     | Industry         | Estimation of excess air coefficient on coal combustion processes via gauss model and artificial neural network                     | 2021 | ANN                    | X                    | X         |                | X                      | X                                      |                   | The main object was to model the relationship between the flame image obtained by a CCD camera and the excess air coefficient.   |                   |                            | All proposed methods can perform matching below 1 sec.   |
| Golgyaz et al.      | Industry         | Artificial neural network regression model to predict flue gas temperature and emissions with the spectral norm of flame image      | 2019 | ANN                    | X                    | X         |                | X                      |  |                   | In-boiler combustion process of coal fired burner was recorded with CCD camera . The flue gas temperature and emissions are estimated from flame images.   |                   |                            | Expensive flue gas analyser are no longer needed. The estimation accuracy of the flue gas temperature is 99%.  |
| Gómez et al.        | Industry         | Flame Classification through the Use of an Artificial Neural Network Trained with a Genetic Algorithm                               | 2013 | ANN-GA                 | X                    | X         |                | X                      | X                                      |                   | The main object was to train an ANN with a GA using the electromagnetic spectrum signal of   |                   |                            | All flame classes were classified with a high percentage while using ANNs trained with the proposed GA .   |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren         | Anwendungsgebiet | Titel  | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik | Vergleichsmethode | Ergebnisse   |
|-----------------|------------------|--|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|-------------------|-------------------|--|
|                 |                  |  |      |                        |                      |           |                |                        |  |                   | a combustion process  |                   |                   |  |
| Zhezhe et al.   | Industry         | Combustion stability monitoring through flame imaging and stacked sparse autoencoder based deep neural network | 2020 | DNN                    | X                    | X         |                | X                      | X                                      |                   | A DNN model is established for predicting combustion stability.   |                   |                   | An automatic generation of combustion stability could be achieved. Quantitative and qualitative evaluation of combustion stability are presented. The Generalization and robustness of the model are verified. |
| Onat et al.     | Industry         | Prediction of combustion states from flame image in a domestic coal burner                                     | 2021 | ANN                    | X                    | X         |                | X                      |  | X                 | A measurement system that estimates emission from flame images in a domestic coal burner is proposed.             |                   |                   | The proposed system has a simpler structure and higher accuracy compared to its counterparts previously presented in the literature.   |
| Sutjatha et al. | Industry         | Monitoring Power Station Boilers Using ANN and Image Processing  | 2013 | ANN                    | X                    | X         |                | X                      |  | X                 | The study deals with monitoring the combustion quality of power station boilers using AI methods.                 |                   |                   | The study showed that for this work the back propagation algorithm is giving better result as compared to other conventional techniques.   |
| Zhang et al.    | Industry         | Analysis and neural network prediction of combustion stability for industrial gases                            | 2021 | NN                     | X                    | X         |                | X                      | X                                      | X                 | Neural network models are presented to predict long term oscillating combustion processes. The characteristics of |                   |                   | The study showed the robustness of NN models.  |

# Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

| Autoren      | Anwendungsgebiet | Titel   | Jahr | Verwendete KI/ML-Tools | Prozess-Modellierung | Effizienz | Therm. Komfort | Optimierung & Prognose | Qualitäts-Management & Fehlererkennung | Adaptive Regelung | Zielsetzung   | Stand der Technik                  | Vergleichsmethode | Ergebnisse   |
|--------------|------------------|---|------|------------------------|----------------------|-----------|----------------|------------------------|--|-------------------|---|------------------------------------|-------------------|--|
| Jin Woo Moon | Building         | Comparative performance analysis of the artificial-intelligence-based thermal control algorithms for the double-skin building | 2015 | ANN, FIS, Fuzzy logic  | X                    | X         |                | X                      |  | X                 | proposing a diverse AI-based algorithm for the heating season | conventional rule based algorithms | simulations       | FL and ANFIS algorithms were superior to the ANN algorithm in terms of providing better thermal conditions<br><br>algorithm proved its potential to be the most energy-efficient and stable strategy |

## 8 Kontaktdaten

ProjektleiterIn: Ass.Prof. Dr. Rene Prieler  
Institut/Unternehmen: Technische Universität Graz, Institut für Wärmetechnik  
Kontaktadresse: Inffeldgasse 25b, 8010 Graz  
Email: [rene.prieler@tugraz.at](mailto:rene.prieler@tugraz.at)  
Website: [www.iwt.tugraz.at](http://www.iwt.tugraz.at)