

Künstliche Neuronale Netzwerke für die Anwendung in der Solarthermie

bearbeitet von:

Dr. Wolfgang Kramer

15. März 2019

Anschrift:

Fraunhofer-Institut
für Solare Energiesysteme ISE
Bereich Thermische Systeme und Gebäude
Heidenhofstrasse 2
79110 FREIBURG
Deutschland

Fraunhofer ISE

Künstliche Neuronale Netzwerke für
die Anwendung in der Solarthermie

Danksagung

Das Projekt „Neuronale Netzwerke für die Anwendung in der Solarthermie“ (ANNSolar) wurde mit Mitteln des Bundesministeriums für Wirtschaft (BMWi) unter dem Förderkennzeichen FKZ 325548 durch den Projektträger Jülich (PTJ) gefördert. Der Autor dankt für die Unterstützung. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages



Dank gilt auch den Firmen Sorel Mikroelektronik GmbH, Steca Elektronik GmbH und Prozeda GmbH für die Unterstützung insbesondere bei der Bewertung der Arbeitsergebnisse.

Inhalt

Nomenklatur	7
1 Vorbemerkung	10
2 Einleitung	10
3 Methodik „Neuronale Netzwerke für die Solarthermie“	11
3.1 Einführung „künstliche Neuronale Netzwerke“	11
3.2 Netz Topologien	13
3.2.1 Feed-forward (FF) Topologie	14
3.2.2 Recurrent Topologie (RC)	15
3.2.3 Vollständig verbundene Topologien	16
3.3 Datenvorverarbeitung	17
3.3.1 Klassische Datenvorverarbeitung	17
3.4 Lernalgorithmen	17
3.4.1 Überwachtes Lernen	18
3.4.2 Training von dynamischen Netzen	24
3.4.3 Nicht überwachtes Lernen	25
3.5 Schlussfolgerungen	27
4 Regelungskonzept	27
4.1 Anforderungen an ein ANN-Regelungskonzept	27
4.1.1 Hydraulik einer typischen solarthermische Anlage zur kombinierten Heizung und Warmwassererzeugung	28
4.1.2 Funktionalitäten und Potenziale neuronaler Netze für die Anwendung in der Solarthermie	29
4.1.3 Priorisierung der ANN Funktionalitäten für solarthermische Kombianlagen	33

4.2	ANN-Regelungsansatz	34
5	Entwicklung des ANN-basierten Regelungsprogramms.....	38
5.1	ANN-Prognose Software WinANN.....	38
5.1.1	Anforderungen an die ANN Software.....	38
5.1.2	Hauptstruktur und Komponenten der ANN Software.....	41
5.1.3	WinANN-Software.....	44
5.1.4	Funktionen der WinANN-software	46
5.2	Das Regelungsprogramm.....	50
5.2.1	Verzeichnis der Sensoren, Aktoren und Parameter der Regelung	50
5.2.2	Input-Output Schnittstelle und Kommunikation (Communication Module).....	55
5.2.3	Das Sicherheitsmodul (Safety check module)	56
5.2.4	Das Ausgabemodul (Output processing module)	57
5.2.5	Regelung der Vorlauf-Solltemperatur des Heizkreises (Modul ANN_1).....	59
5.2.6	Schaltung der Heizkreispumpe.....	66
5.2.7	Ansteuerung des Mischventils (PD bzw. ID Regler)	66
5.2.8	Regelung des Pelletbrenner-Signals (an/aus) (Modul ANN_2).....	69
5.2.9	Das Wetterprognose-Modul (Weather forecast module)	76
5.3	Kombinierter linearer/ nicht-linearer Prognoseansatz	76
5.3.1	Linearer Ansatz (LSI Linear System Identifier)	76
5.3.2	Nicht linearer Ansatz (ANN Artificial Neural Network)	79
5.3.3	Analyse von linearem und nicht-linearem Anteil der Prognosefunktionen	79
5.4	Erstellung von Startmatrizen für den erstmaligen Einsatz der Regelung ohne das Vorhandensein von Trainingsdaten.....	86
5.4.1	Empirische Überprüfung der Startmatrix.....	87
5.5	Erforderliche Rechnerleistung und Speicherkapazität der ANN Algorithmen.....	89
5.5.1	Erforderlicher Speicherbedarf und notwendige Rechnerleistung für LSI	90
5.5.2	Erforderliche Rechnerleistung für ANN im Regelungsmodus.....	91

5.5.3	Erforderliche Rechnerleistung für ANN im Trainingsmodus.....	93
6	Bewertung der Funktionalität im realen Gebäude.....	95
6.1	Reales Testgebäude.....	95
6.1.1	Beschreibung der Testanlage	95
6.2	Implementierung der ANN-Regelung im realen Gebäude.....	104
6.2.1	Implementierte Netzstruktur und Training der Neuronale Netze.....	104
6.2.2	Bewertung der ANN-Prognosefunktionalität.....	109
6.2.3	Eingabe-/Ausgabeschnittstelle ANNssoftware zur vorhandenen Regelung	116
6.3	Verhalten der ANN-Regelung im realen Gebäude	121
7	Energetische Bewertung.....	123
7.1	Modellierung des Gebäudes	123
7.1.1	Thermischer Speicher.....	128
7.1.2	Solarkreis	130
7.1.3	Kesselkreis	131
7.1.4	Trinkwarmwasserkreis	132
7.1.5	Heizkreis	133
7.1.6	Wetterdaten	134
7.2	Regelung im Simulationsmodell	135
7.2.1	Konventionelle Regelung.....	135
7.2.2	ANN-Regelung	140
7.3	Simulationsergebnisse	143
7.3.1	Bewertung der Regelungsansätze	144
7.3.2	Konventionelle Regelung mit konstanter Heizkreisvorlauftemperatur.....	147
7.3.3	Konventionelle Regelung mit optimierter Heizkurve.....	149
7.3.4	ANN-Regelung	149
7.3.5	Vergleich der drei Regelungsmodi.....	151
7.4	Ergebnisse Energetische Bewertung	157
8	Kosten- /Nutzenanalyse.....	158

8.1	Mögliche Nachteile eines ANN-Regelungsansatzes.....	158
8.2	Vorteile eines ANN-Regelungsansatzes.....	160
8.3	Ergebnisse der Kosten- /Nutzenanalyse	161
9	Zusammenfassung und Ausblick	162
10	Literaturverzeichnis	165
11	Tabellenverzeichnis	166
12	Abbildungsverzeichnis.....	167

Nomenklatur

Häufig benutzte Symbole, Indizes

Symbol, Index	Beschreibung	ggfs. Wert	Einheit
amb	Außen-... (ambient)		
B_{closed}	Anzeige, ob das Ventil vollständig geschlossen wurde (=1) oder noch offen ist (=0)		
C_{close}	Schließzeit-Zähler. Startet, wenn angefangen wird das Ventil zu schließen. Wenn ab diesem Zeitpunkt nur noch geschlossen wird, kann damit bestimmt werden, ob das Ventil vollständig geschlossen ist, wenn die Zeit x_{close} erreicht wurde		s
CC_{fc}	Bewölkungsgrad-Prognose (Cloud cover)		%
dw	Trinkwasser (domestic water)		
$DT_{dw,tg}$	Temperaturüberhöhung Trinkwasser-Speichertemperatur	3	°C
$DT_{hc, safe}$	Sicherheits-Temperaturabstand zwischen tatsächlicher und maximaler Vorlauf Solltemperatur. D.h. die Vorlauftemperatur wird so bestimmt, dass $T_{f,tg} \leq T_{hc,lim} - DT_{hc, safe}$	5	°C
$DT_{st, hc}$	Temperaturüberhöhung Heizkreis-Vorlauf-Speichertemperatur	3	°C
f	Vorlauf (flow)		
fc	Prognose/Vorhersage (forecast)		
GNI_{fc}	Solare Normalstrahlung-Prognose (Global Normal Irradiance)		W/m ²
hc	Heizkreis (heating circuit)		
k_I und k_D	Parameter der PD-Regelung von x		
K	Größe eines Eingabevektors		
m	Größe eines Eingabevektors		
M	Größe eines Ausgabevektors		
M_i	Matrix, welche die Gewichte der i-ten Schicht enthält		
N	Größe des Trainingsdatensatzes, r Anzahl von Messungen oder Anzahl von Zeitschritten		
Q_{Aux}	Wärmemenge, die vom fossilen Nachheizsystem zugeführt wird		kWh
RL bzw. ret	Rücklauf (return)		

Symbol, Index	Beschreibung	ggfs. Wert	Einheit
$R(x_k)$	Zeitreihe einer Input-Komponente. D.h. die Menge an Werten $\{x_k(t_1), x_k(t_2), \dots, x_k(t_K)\}$		
st	Speicher (storage)		
S_b	Betriebszustand des Brenners (nur an/aus) (= 1A11)	0 oder 100	%
$S_{b,ave}(t_0)$	Durchschnittlicher Brennerzustand im Zeitintervall $[t_{-1}; t_0]$		%
$S_{b,ave,bef}(t_0)$	Durchschnittlicher Brennerzustand im Zeitintervall $[t_{-2}; t_{-1}]$		
t_0	Startzeitpunkt/Zeitpunkt der Berechnung		
$t_{b,min}$	Minimale Brennerlaufzeit, ab Einschaltung läuft der Brenner immer mindestens diese Zeit	15	min
$t_{com,min}$	Minimale Kommunikationszeit zwischen zwei vom PC an die CU gesendeten Signalen und zwischen zwei empfangenen Signalen	1	s
t_N	Endzeitpunkt der ANN-Prognose		
t_{prog}	ANN-Prognosezeitraum $t_{prog} = t_N - t_0 = N \cdot t_s$		
t_s	ANN-Zeitschritt		
$t_{x,cycle}$	Zykluszeit, x z.B. „f“ (Heizkreisvorlauf), „b“ (Brenner), „mix“ (Mischventil)		
T bzw. T	Temperatur		°C
$T_{amb,fc}$	Außentemperaturprognose		°C
$T_{col,lim}$	Maximale Kollektortemperatur. Wenn die Temperatur im Kollektor diesen Wert überschreitet kommt es zu Verdampfung des Fluids	125	°C
T_{CW}	Kalhwassertemperatur (Cold Water)		°C
T_f	Vorlauftemperatur Heizkreis (1T04)		°C
$T_{f,tg}$	Vorlauf Solltemperatur Heizkreis (1T04 wird hierauf geregelt)		°C
$T_{f,min}$	Vorlaufgrenztemperatur. Falls $T_{f,tg} \leq T_{f,min}$, wird der Zulauf des Warmwassers in den Heizkreis geschlossen.	20	°C
$T_{hc,lim}$	Maximale Heizkreistemperatur, der Vorlauf für Boden- und Raumheizung darf diesen Wert nicht überschreiten	65	°C
T_{dw}	Trinkwarmwassertemperatur		
$T_{dw,tg}$	Solltemperatur Trinkwarmwasser. kann vom Nutzer in einem Zeitplan eingestellt werden		°C
T_r bzw. T_{room}	Raumtemperatur		
$T_{r,tg}$	Soll-Raumtemperatur. Kann vom Nutzer in einem Zeitplan eingestellt werden		°C
$T_{st,dw,tg}$	Mindesttemperatur im Speicher Pos. 7 (1T14), um $T_{dw,tg}$ im Trinkwasser zu gewährleisten. $T_{st,dw,tg} = T_{dw,tg} + DT_{dw,tg}$		°C
$T_{st,hc,tg}$	Mindesttemperatur im Speicher Pos. 8 (1T13), um $T_{f,tg}$ im Heizkreis zu gewährleisten. $T_{st,hc,tg} = T_{f,tg} + DT_{st,hc}$		°C

Symbol, Index	Beschreibung	ggfs. Wert	Einheit
$T_{st,i}$	Speichertemperatur an Position i ($i = 1, \dots, 8$). 1: ganz unten, 8: ganz oben, siehe „Sensoren und Aktoren“-Tab.		°C
$T_{st,lim}$	Maximale Speichertemperatur, darf an keiner Position im Speicher überschritten werden	85	°C
T_{ws}	Kaminofentemperatur (wood stove) (= 1T15)		
$T_{x,soll}$ bzw. $T_{x,tg}$	Solltemperatur		°C
$\Delta T_{x,on}$	Temperaturhub, welcher als Einschaltkriterium dient		
$\Delta T_{x,off}$	Temperaturhub, welcher als Abschaltkriterium dient		
VL	Vorlauf (flow)		
W	Gewichte des ANN. Ein Index beschreibt die Zugehörigkeit zu Schicht und Position innerhalb der Schicht sowie die Verknüpfungswege zwischen Neuronen.		
ΔW	Änderung der Gewichte		
ws	Kaminofen (wood stove)		
x	Vorzeichenbehaftete Drehzeit des 3-Wege-Mischventil-Motors. Bei $x > 0$ wird geschlossen. Bei $x < 0$ wird geöffnet. x wird durch eine PD Regelung bestimmt.		s
\vec{x}	ANN-Eingabe (Input)-Vektor mit Komponenten x_i		
x_{close}	Zeit zur vollständigen Schließung des 3-Wege-Mischventil	130	s
x_{min} / x_{max}	Minimale/maximale Drehzeit des 3-Wege-Mischventil-Motors		s
\vec{y}	ANN-Ausgabe (Output)-Vektor mit Komponenten y_i		
ε	Halber quadratischer Fehler.		
ξ	Mittelwert von ε , wenn der gesamte Trainingsdatensatz betrachtet wird		
ω	Gewichte des ANN. Ein Index beschreibt die Zugehörigkeit zu Schicht und Position innerhalb der Schicht sowie die Verknüpfungswege zwischen Neuronen.		

Abkürzungen

CM	Koppelmodul bzw. Coupling module (Hardware)
CU	Control Unit (Hardware)
KM	Koppelmodul bzw. Coupling module (Hardware)
PC	Lokaler Rechner, auf dem die „ANNSolar“-Software läuft
PU	Power Unit (Hardware)

1 Vorbemerkung

Die Fachliteratur zu künstlichen neuronalen Netzen ist überwiegend in englischer Sprache verfasst. Viele der verwendeten Fachbegriffe sind daher in deutschen Texten nicht einheitlich definiert. In nachfolgendem Text werden daher zum Teil englische Begriffe verwendet, um Missverständnissen vorzubeugen.

2 Einleitung

Wesentlich für den zukünftigen Erfolg der Energiewende ist die Realisierung einer signifikanten Einsparung fossiler Energie im Gebäude. Solarthermie kann hierzu einen Beitrag leisten. Die Kosten der Wärmeerzeugung durch Solarthermie müssen jedoch signifikant sinken.

Eine wichtige systemtechnische Komponente von Heizungsanlagen ist die Regelung. Dabei entstehen wesentliche einmalige Kosten bei der Programmierung der Regelalgorithmen. Sich regelmäßig wiederholende Kosten entstehen auch bei der Installation und Inbetriebnahme von Heizungsanlagen. Hier könnte die Nutzung der Methodik von Neuronalen Netzwerken Kostenvorteile erschließen. Gleichzeitig bieten sich damit auch ganz neue Möglichkeiten der Regelungsoptimierung in Hinblick auf die Energieeffizienz.

Wesentliches Ziel des Projektes ANNSolar (Artificial Neural Networks Solar) ist es, mögliche monetäre und technische Vorteile der Methodik der künstlichen Neuronalen Netzwerke für die Solarthermie nutzbar zu machen und zu belegen. Die Option, mit künstlichen Neuronalen Netzwerken selbstlernende Algorithmen zu generieren, erlaubt wesentlich einfacher komplexe Regelungsstrategien zu realisieren, was eine Steigerung der Energieeffizienz ermöglicht. Wie die Ergebnisse des Projektes vermuten lassen, ist die Anwendung von künstlichen Neuronalen Netzen aber auch für die Gebäudebeheizung mit anderen Wärmeerzeugungstechnologien vielversprechend.

Im vorgestellten Projekt geht es zunächst darum, die Grundlagen für die Anwendung von Neuronalen Netzwerken zu schaffen. Neben der Entwicklung geeigneter Netztopologien und der Defini-

tion von Hardwareanforderungen, stehen insbesondere Trainingsalgorithmen und selbstlernende Algorithmen im Fokus der Arbeit.

Im zweiten Schritt wird dargestellt wie eine ANN-Regelung realisiert werden kann und welche Energieeinsparpotenziale möglich sind. Kosten- und Nutzen werden mit der Unterstützung von Industriepartnern analysiert.

Abschließend wird in einem realen Gebäude die prinzipielle Funktionsfähigkeit des ANN-Regelungsansatzes demonstriert.

3 Methodik „Neuronale Netzwerke für die Solarthermie“

3.1 Einführung „künstliche Neuronale Netzwerke“

Neuronale Netzwerke sind in der Lage, ähnlich dem menschlichen Gehirn, Regelungsstrategien anhand von „erlebten“ Beispielen zu entwickeln. Der Aufbau orientiert sich dabei an den Erkenntnissen der Biologie über das Funktionieren des menschlichen Gehirns (Abbildung 1)

Ein technisches Neuronales Netz besteht aus simplen Recheneinheiten, den Neuronen, sowie gerichteten, gewichteten Verbindungen zwischen diesen. Das mathematische Modell eines solchen Neurons ist in Abbildung 2 dargestellt. Die verschiedenen Eingangssignale (Input) werden mit einem Gewicht ω_{ik} multipliziert und aufsummiert. Dieser Wert wird an eine Übertragungsfunktion übergeben, welche den Charakter einer Schwellwertfunktion besitzt. Das heißt, wenn die Summe einen bestimmten Schwellwert erreicht hat, ist das Ausgangssignal (Output) +1 im anderen Fall -1. Für die genaue Definition der Übertragungsfunktion bestehen verschiedene Möglichkeiten. Auf die Auswahl in unserem Falle wird später eingegangen. Einzelne Neuronen werden dann zu einem Neuronalen Netz zusammengesetzt wobei der Output eines Neurons der Input eines weiteren Neurons darstellt (Abbildung 3). Zunächst werden die Eingangssignale in einer Eingangs-




Abbildung 1: Neuronales Netzwerk des menschlichen Gehirns (aus [12])




Abbildung 2: Mathematisches Modell eines Neurons

schicht (Input layer) verarbeitet. Danach folgen mehrere verborgene Schichten (hidden layer). Am Ende steht die Ausgangsschicht (Output layer) welche das Ausgangssignal (Output) generiert.

Das interessanteste Merkmal neuronaler Netze ist ihre Fähigkeit zu lernen. Lernen bedeutet in diesem Zusammenhang, dass das System in der Lage ist, eine Korrelation zwischen Eingangssignalen und Ausgangssignalen herzustellen. Dabei verändert sich das System so, dass Eingangs und er-




Abbildung 3: Beispiel eines technischen neuronalen Netzes




Abbildung 4: Schematischer Vergleich zwischen Feed-forward und Recurrent Topologie

wartete Ausgangssignale möglichst gut zueinander passen. Es lernt mit Hilfe von Trainingsdaten. Wird diese Funktionalität für die Simulation technischer Prozesse genutzt, so muss keinerlei Information über physikalische Zusammenhänge verfügbar sein. Es müssen lediglich Trainingsdaten zur Verfügung stehen, welche das Verhalten des Prozesses ausreichend charakterisieren. Anders ausgedrückt entspricht das Lernen neuronaler Netz dem Herstellen einer Korrelation zwischen bekannten Eingangs- und Ausgangsdaten.

Für eine detailliertere Einführung in das Thema in Deutsch und Englisch sei auf die Veröffentlichung von Kriesel verwiesen [1].

3.2 Netz Topologien

Netz Topologien von künstlichen neuronalen Netzwerken (englisch: Artificial Neural Networks ANN) können unterschiedlich aufgebaut sein. Zunächst sind sogenannte Feed-Forward (FF) Topologien von Recurrent (RC) Topologien zu unterscheiden (Abbildung 4). Bei FF Topologien werden die Ausgangssignale einer Schicht konsequent zu Eingangssignalen der nächsten Schicht. Der Aufbau der Topologie ist klar in Schichten gegliedert. In RC Topologien können Eingangssignale und Ausgangssignale verschiedener Neuronen in beliebiger Systematik verknüpft werden. Damit ergibt sich die Möglichkeit, das Ausgangssignal eines Neurons am Ende der Kette als Eingangssignal für ein Neuron am Anfang der Kette zu definieren. Durch diese Rückkopplung ergibt sich eine Art Gedächtnis, wenn man davon ausgeht, dass die Verarbeitung der Signale in den Neuronen sequentiell abläuft. Das Ausgangssignal dieses Neurons am Anfang der Kette hängt demnach nicht nur von den Eingangssignalen des gesamten ANN ab, sondern auch von den Ausgangssignalen eines Neurons ab, welches aufgrund der sequentiellen Abarbeitung Informationen über einen früheren Zustand beinhaltet.

Darüber hinaus gibt es Topologien, bei welchen jedes Neuron mit jedem anderen direkt verknüpft ist, sogenannte vollständig verbundene Topologien.

Grundsätzlich bestehen keine Einschränkungen bezüglich der Definition möglicher ANN Topologien. Für das Projekt ANNsolar wurden jedoch nur die drei genannten Topologien vertieft analysiert.

3.2.1 Feed-forward (FF) Topologie

Bei der FF Topologie hängt das Ausgangssignal einer Schicht direkt von den Ausgangssignalen der vorhergehenden Schicht ab. Es existieren keine Rückkopplungen, welche einen Einfluss von vorhergehenden Zuständen des ANN auf den aktuellen Zustand ausüben. Damit existiert kein „Gedächtnis“, wie weiter oben beschrieben. Aus dem allgemeinen Approximationstheorem lässt sich ableiten, dass eine Topologie mit mindestens 2 Schichten, d.h. mindestens einer verborgenen Schicht und einer Ausgabeschicht, und einer ausreichenden Zahl von Neuronen in der verborgenen Schicht jede beliebige mathematische Funktion approximieren kann. Die Kunst dabei ist, die richtige Anzahl von Neuronen und die richtige Anzahl von Schichten auszuwählen. Die Durchsicht der aktuellen Literatur zu neuronalen Netzwerken zeigt, dass es bisher keine mathematischen Regeln für die Bestimmung dieser Parameter gibt. Lediglich einige erfahrungsbasierte Daumenregeln sind bekannt. Fehler bei der Wahl dieser Parameter führen nicht notwendigerweise zum Scheitern der Methodik an sich, Folgen sind jedoch häufig weniger genaue Ergebnissen, erhöhter Trainingsaufwand und das wahrscheinlichere Auftreten des Problems der Überanpassung. Letzteres bedeutet, dass zwar Trainingsdaten genau reproduziert werden können, die Ergebnisse bei Eingabedaten




Abbildung 5: vollständig verbundene Topologie, bei der alle Neuronen der ersten verdeckten Schicht miteinander verknüpft sind.

ten, welche nicht genau den Trainingsdaten entsprechen, aber sehr ungenau werden.

FF Topologien könne für zwei Arten von ANN genutzt werden. Zum einen für Multi-Layer Perceptron (MLP) [2], Kap. 4 und zum anderen für Radial-Based Functions (RBF) [2], Kap. 5. RBF besteht nur aus einer verborgenen Schicht, MLP kann eine beliebige Anzahl von Schichten besitzen. Durch diese Beschränkung bei RBF ergibt sich eine bessere mathematische Beherrschbarkeit. So kann die Anzahl der notwendigen Neuronen relativ genau abgeschätzt werden, wenn der Umfang der Trainingsdaten bekannt ist. Die Möglichkeiten, unterschiedliche Übertragungsfunktionen zu nutzen, sind größer als bei MLP. Da für MLP bisher keine mathematischen Regeln für die Bestimmung der Größe und der Struktur der ANN existiert, wird hier üblicherweise eine Cross-Validierungsmethode angewendet [2]. Dabei werden unterschiedliche Strukturen und Größen von ANN generiert und deren Leistungsfähigkeit in Test verglichen. Das beste ANN wird dann ausgewählt.

3.2.2 Recurrent Topologie (RC).

Aufgrund der weiter oben beschriebenen Fähigkeit dieser Topologie, bei der Bestimmung von Ausgangssignalen auch frühere Zustände des Systems zu berücksichtigen, dem „Gedächtnis“, können mit dieser Topologie dynamische Systeme modelliert werden. Im Projekt ANNsolar wird diese Fähigkeit benötigt, um zum Beispiel die Dynamik der Gebäudeerwärmung und der Abkühlung zu bestimmen.

Der verbreitete Ansatz, lineare und nicht-lineare dynamische Systeme mit Hilfe von ANN zu modellieren, lässt sich folgendermaßen beschreiben.

$$\frac{d\vec{x}}{dt} = f(\vec{x}, \vec{u}) \rightarrow \vec{y} = C\vec{x} + D\vec{u} \quad (3.1)$$

Dabei ist \vec{x} der Vektor des aktuellen Zustandes des Systems mit der Dimension q , f ist eine beliebige lineare oder nichtlineare Funktion welche die Systemdynamik beschreibt. \vec{u} ist der Vektor der momentanen Eingangsgrößen mit der Dimension m , \vec{y} ist der Vektor der Ausgangsgrößen mit der Dimension n , C ist eine Matrix, welche den Zusammenhang zwischen dem momentanen Zustand des Systems und dem Ausgangsdaten des Systems darstellt. Diese besitzt die Dimension $n \times q$, D ist die Matrix welche den direkten Einfluss der Eingangsgrößen auf die Ausgangsgrößen beschreibt. Die Dimension von D ist $n \times m$.

Die Abhängigkeit der Ausgangsgrößen wird also zerlegt in eine Abhängigkeit von den Eingangsgrößen und eine Abhängigkeit von dem vorhergehenden Zustand des Systems. Am Beispiel der Gebäudedynamik bedeutet dies, dass die Temperatur des Gebäudes zu einem bestimmten Zeitpunkt zum einen von den Eingangsgrößen, wie zum Beispiel Solarstrahlung, Vorlauftemperatur des Heizkreislaufs und Außentemperatur, zum anderen aber auch von der Temperatur des Gebäudes zu einem früheren Zeitpunkt abhängt.

Um für die Aufgabenstellung des Projektes ANNsolar die Vorgehensweise noch stärker zu strukturieren, soll diese folgendermaßen beschrieben werden. Kern des ANN-Netzes ist eine Feed-Forward Struktur, welche durch eine zeitlich verzögerte Rückkopplung $\vec{z}_{(t-1)}$ in der Lage ist, dynamische Effekte abzubilden. Damit entsteht eine Recurrent Topologie. Wie in Gleichung (3.1) beschreibt die Matrix D den direkten (nicht dynamischen) Einfluss der Eingangsgrößen auf die Ausgangsgröße. Die Matrix C verknüpft Zustand des Systems mit den Ausgangsgrößen. Die Pfeile beschreiben die Übergabe der Datenvektoren. Erste Versuche zeigen, dass dieser Ansatz die Gebäudedynamik für die genannte Aufgabenstellung ausreichend gut beschreibt. Außerdem reduziert er Schwierigkeiten beim Training, welche bei komplexer strukturierten RC Topologien zu beobachten sind. Testläufe mit einfachen Gebäudemodellen zeigen, dass dieser Ansatz zielführend ist.

3.2.3 Vollständig verbundene Topologien

Ein weiterer Topologie Ansatz ist der der vollständig verbundenen Topologien. Hierbei ist jedes Neuron der verborgenen Schicht mit jedem anderen Neuron dieser Schicht verbunden. Wesentli-




Abbildung 6: Modellierung eines dynamischen Systems mit einer Recurrent-Topologie bestehend aus einem Feed-forward Kern und einer zeitlich verzögerte Rückkopplung

che Schwierigkeiten dieses Ansatzes sind der große Trainingsaufwand und die schlechten Konvergenzeigenschaften des Systems. Bisherige Umsetzungsversuche legen nahe, dass dieser Ansatz für die Aufgabenstellung im Projekt ANNsolar nicht erfolgversprechend ist.

3.3 Datenvorverarbeitung

Für jedes Neuron der verborgenen Schichten sind normalerweise mehrere unterschiedliche Eingangssignale definiert. Die Spannweite der Daten kann sehr stark variieren. Einige Signale mögen zum Beispiel zwischen $-0,793$ und $+0,800$ variieren, andere zwischen -10 und $+80$. Wenn diese Eingangssignale mit dem gleichen Neuron verbunden werden und beim Trainingsstart mit ähnlichen oder zufällig gewählten Gewichten versehen sind, so wird zunächst das kleinere Signal kaum berücksichtigt. Dies ändert sich erst nach vielen Iterationsschritten. Dadurch entstehen lange Trainingszeiten.

Abhilfe schafft eine Modifikation der Daten schon vor der eigentlichen Verarbeitung durch die Rechenalgorithmen des neuronalen Netzes. Wir wollen dies hier Datenvorverarbeitung (engl. data pre-processing oder data pre-treatment) nennen. Ziel ist hierbei eine Normierung der Daten.

3.3.1 Klassische Datenvorverarbeitung

Nach klassischer Vorgehensweise aus der Statistik wird eine Normierung der Daten durch die Berechnung des Mittelwertes der Trainingsdaten und eines daraus abgeleiteten Off-sets realisiert. Im zweiten Schritt wird die Spannweite der Eingangssignale auf ± 1 um den Mittelwert reduziert. Dies entspricht einer Zentrierung der Daten um den Mittelwert und einer Normierung der Spannweite auf die Größe von ± 1 . Diese Datenvorverarbeitung muss dann auch auf alle Eingangsdaten während des Betriebes eines neuronalen Netzes angewandt werden und kostet kontinuierlich Rechenleistung.

Am elegantesten wird dieser Ansatz durch die Zuordnung eines Eingangsneurons umgesetzt, welches diese Aufgabe für jedes Eingangssignal erledigt. Durch die Anpassung der Gewichte wird die Spannweite standardisiert, der Offset wird durch ein sogenanntes Bias Signal dargestellt.

3.4 Lernalgorithmen

Grundsätzlich verändert sich ein Neuronales Netz mit der Veränderung seiner Bestandteile. Ein Neuronales Netz kann also lernen, indem es neue Verbindungen entwickelt, vorhandene Verbindungen löscht, Verbindungsgewichte verändert, Schwellwerte von Neuronen ändert, eine oder mehrere der Neuronenfunktionen abwandelt, neue Neuronen entwickelt oder vorhandene Neuronen löscht.

Nachdem die Topologie, also die Struktur der Verbindungen zwischen den Neuronen, für ein künstliches neuronales Netz gewählt wurde, gilt es, die freien Parameter dieses Netzes zu bestimmen. Dieser Prozess soll „Lernen“ genannt werden. Grundsätzlich sind Lernen mit Überwachung und nicht überwachtes Lernen zu unterscheiden. In diesem Bericht soll nur auf das überwachte Lernen eingegangen werden, welches für die beschriebenen Regelungsansatz relevant ist.

Überwachtes Lernen wird angewendet, wenn eine genügend große Anzahl von Eingangs- und gewünschten/erwarteten Ausgangsdaten zur Verfügung steht, deren funktionaler Zusammenhang nicht bekannt ist. Ziel ist dann, eine ANN-basierte Funktion zu erzeugen, welche diese unbekannte Funktion möglichst genau abbildet. Die mittlere Abweichung zwischen der ANN-Funktion und dem unbekanntem funktionalen Zusammenhang beschreibt die Güte der ANN-Funktion. Um eine möglichst gute Übereinstimmung zwischen ANN-Funktion und unbekannter Funktion herzustellen, ist die Auswahl der richtigen Struktur und Größe der Netztopologie sowie eines geeigneten Trainingsalgorithmus entscheidend. Die wesentlichen Herausforderungen von überwachtem Lernen sind das Auffinden globaler Fehlerminima, wie sie auch bei anderen Optimierungsverfahren bekannt sind, sowie die Gefahr des Over-Fittings. Letzteres ist auch bekannt bei der Approximation von Datensätzen durch Polynome, wenn der Grad des Polynoms zu groß gewählt wird. Dann werden zwar die vorliegenden Datensätze gut abgebildet, Zwischenwerte aber sehr schlecht. Ähnliches ist auch bei ANN-Netzen bei ungeeigneten Topologien und Trainingsalgorithmen zu beobachten.

In der Literatur finden sich Beschreibungen einer Vielzahl von Algorithmen und Daumenregeln für das Training von ANN. Jede Methode hat ihre spezifischen Vor- und Nachteile und benötigt entsprechend unterschiedliche Prozessorleistung, Speicherkapazität und stellt unterschiedlich komplexe Anforderungen an die mathematische Behandlung. Ziel der nachfolgenden Abschnitte ist die Beschreibung der Ansätze welche für das Projekt ANNsolar am besten geeignet erscheinen. Die Auswahl basiert auf umfangreichem Studium der Literatur, Analysen und zum Teil Implementierung und Testläufe entsprechender Algorithmen. Sie spiegeln den Wissenstand im Projekt wieder.

3.4.1 Überwachtes Lernen

Ziel des überwachten Lernens ist, eine mathematische Beziehung zwischen bekannten Eingabe- und Ausgabedaten zu konstruieren. Diese mathematische Beziehung oder Funktion dient dazu, für zukünftige Eingabedaten die zugehörigen Ausgabedaten oder erwartete Ergebnisdaten zu schätzen. Solange diese zukünftigen Eingabedaten sich im Datenraum der Trainingsdaten befinden, ist eine gute Interpolation zu erwarten. Ggfs. kann auch eine Extrapolation in der Nähe des Trainingsdatenraumes noch erfolgreich sein.

Innerhalb der Trainingsphase findet ein Optimierungsprozess statt, welcher versucht, die besten Werte für die freien Parameter eines ANN Netzes zu finden, um den vom ANN Netz generierten Output möglichst gut mit dem erwünschten Output in Übereinstimmung zu bringen.

Ein zielführender Ansatz betrachtet zunächst einen einzelnen Datensatz (bestehend aus Eingabe- und Ausgabedaten) aus dem gesamten Trainingsdatenpool. Die Gewichte der ANNstruktur werden dann geringfügig so verändert, dass die Übereinstimmung zwischen erwarteten und vom ANN-Netz erzeugten Ausgabedaten sich verbessert. Im nächsten Schritt wird ein zweiter Datensatz zufällig ausgewählt und der gleichen Prozedur unterzogen. Wird dieser Prozess häufig genug wiederholt, so werden die Gewichte gegen fixe Werte konvergieren, die im Mittel das beste Ergebnis liefern. Je nach Komplexität des Netzes und Problemstellung können Tausende, Millionen oder mehr Iterationsschritte notwendig sein. Man spricht in diesem Fall von einem stochastischen Ansatz oder auch sequenziellem Training.

Ein zweiter Ansatz nutzt jeweils den gesamten Trainingsdatensatz, um Gewicht für Gewicht zu optimieren. Hierbei wird nacheinander für jedes Gewicht der Wert ermittelt, der für den gesamten Datensatz die geringste mittlere Fehlerabweichung zwischen Eingabe- und gewünschten Ausgabedaten erzeugt. Diese Prozedur wird für alle Gewichte solange wiederholt, bis sich der mittlere Fehler nicht mehr verändert. Dieser Ansatz wird Batch-Training genannt.

Bei beiden Ansätzen erfolgt die Optimierung der Gewichte ausgehend von der letzten Schicht (Ausgabeschicht) hin zur ersten Schicht (Eingabeschicht). Diese Methoden werden daher Back-Propagation-Methoden genannt.




Abbildung 7: Einfache Feed-Forward Struktur mit einer Eingabeschicht, einer verdeckten Schicht und einer Ausgabeschicht

3.4.1.1 Sequenzielles Training

Zunächst wird beim sequenziellen Training ein Wertepaar $\vec{x}, \vec{y}_{Wunsch}$ zufällig ausgewählt. Es handelt sich dabei in der Regel nicht nur um einen skalaren Eingangs- und einen skalaren Ausgangswert sondern um einen Datensatz, welcher aus verschiedenen Größen besteht. Deshalb soll hier allgemeiner ein Eingangs- bzw. Ausgangsvektor betrachtet werden. Der Fehler ist definiert als:

$$\varepsilon = \frac{1}{2} (\vec{y}_{Wunsch} - \vec{y}(\vec{x}, \vec{w}))^T - (\vec{y}_{Wunsch} - \vec{y}(\vec{x}, \vec{w})) \quad (3.2)$$

\vec{w} steht für den Vektor, welche alle Gewichte der ANN-Topologie enthält. $\vec{y}(\vec{x}, \vec{w})$ ist die Ausgabe wenn der gewählte Datensatz \vec{x} als Eingabe gewählt wird. Das hochgestellte T steht für „transponiert“.

Im einfachsten Fall ist von einer Feed-Forward Struktur mit einer Eingabeschicht, einer verborgenen Schicht und einer Ausgabeschicht auszugehen (Abbildung 7). Wegen der einfachen Ableitung ($\tanh'(x) = 1 - \tanh^2(x)$) wird die Funktion $\tanh(x)$ als Übertragungsfunktion benutzt. Die Anpassung jedes Gewichtes wird nach folgendem Schema berechnet. Die tiefgestellten Indizes beschreiben in diesem Fall die Zuordnung der Gewichte zu den Elementen der Eingangsschicht und der verborgenen Schicht. Der hochgestellte Index beschreibt die Zugehörigkeit zur ersten verborgenen Schicht.

$$\frac{\partial \varepsilon}{\partial \omega_{ij}^1} = -(y_{Wunsch_i} - y_i) \frac{\partial y_i}{\partial \omega_{ij}^1} \quad (3.3)$$

$$\frac{\partial y_i}{\partial \omega_{ij}^1} = (1 - y_i^2) y_{N_j} \quad (3.4)$$

$$\Rightarrow \frac{\partial \varepsilon}{\partial \omega_{ij}^1} = -(y_{Wunsch_i} - y_i)(1 - y_i^2) y_{N_j} \quad (3.5)$$

$$\frac{\partial \varepsilon}{\partial \omega_{ij}^0} = - \sum_{k=1}^n (y_{Wunsch_k} - y_k) \frac{\partial y_k}{\partial \omega_{ij}^0} \quad (3.6)$$

$$\frac{\partial y_k}{\partial \omega_{ij}^0} = (1 - y_k^2) \omega_{ki}^1 \frac{\partial y_i}{\partial \omega_{ij}^0} \quad (3.7)$$

$$\frac{\partial y_i}{\partial \omega_{ij}^0} = (1 - y_i^2) x_j \quad (3.8)$$

$$\Rightarrow \frac{\partial \varepsilon}{\partial \omega_{ij}^0} = - \sum_{k=1}^n (y_{Wunsch_k} - y_k)(1 - y_k^2) \omega_{ki}^1 (1 - y_i^2) x_j \quad (3.9)$$

Wenn die partielle Ableitung des Fehlers nach jedem Gewicht ermittelt ist, müssen die Gewichte angepasst werden. Hierfür werden zwei Ansätze eingeführt: Korrekturfaktor, Modifikation des Momentums und Temperatur [2].

3.4.1.1.1 Schrittweitenfaktor (η)

Um ein neues Gewicht zu berechnen, muss vom bestehenden Gewicht die partielle Ableitung des Fehlers nach diesem Gewicht multipliziert mit einem Korrekturfaktor oder Schrittweitenfaktor abgezogen werden.

$$\omega_{ij}^{k\text{ neu}} = \omega_{ij}^{k\text{ alt}} - \eta * \frac{\partial \varepsilon}{\partial \omega_{ij}^k} \quad (3.10)$$

Um Konvergenz sicherzustellen werden für η oft Werte zwischen 0,05 und 0,1 angesetzt. Größere Werte führen zu schnellerer Konvergenz, bergen jedoch die Gefahr von Oszillation oder Instabilitäten.




Abbildung 8: lokale Minima, globales Minimum und Gradienten. Der Index 0 bzw. 1 benennt hier die Anzahl der Iterationsschritte.

Um gleichzeitig schnelle Konvergenz und ein stabiles Verfahren zu erhalten wird in manchen Ansätzen des sequentiellen Trainings η selbst noch variiert. Hierbei startet das Training zunächst mit großen η -Werten, welche dann kontinuierlich reduziert werden.

3.4.1.1.2 Momentum Veränderung

Die numerische Ermittlung eines globalen Minimums einer Funktion mehrerer Variablen kann sehr schwierig werden. Es besteht die Gefahr, dass der Lösungsalgorithmus in lokalen Minima stecken bleibt. Dies bedeutet, dass der Trainingsprozess keine weitere Verbesserung mehr bringt, obwohl tatsächlich optimalere Werte für die Gewichte noch existieren. Diese Problematik ist allen gradientenbasierten Optimierungsmethoden eigen. Die Anpassung der Gewichte entlang der Gradienten führt nicht über die lokalen Minima hinaus. Die ist in Abbildung 8 dargestellt. Um diese Problem zu lösen, wird bei der Neuberechnung jedes Gewichtes diesem ein Momentum hinzugefügt. Das bedeutet zum Beispiel, dass sich der Wert des Gewichts ω_0 im Bereich D befindet. Nach dem ersten Iterationsschritt gemäß Gleichung (3.10) würde ω wahrscheinlich in die Region E und im darauf folgenden Iterationsschritt dann wieder Richtung D zurück wandern.

Wird nun bei der Iteration ein ausreichend großes Momentum I addiert, so steigt die Wahrscheinlichkeit, dass im nächsten Iterationsschritt die Region C mit dem globalen Minimum erreicht wird. Es ist offensichtlich, dass dieses Momentum aber auch nicht zu groß gewählt werden darf, da sonst wegen der Gefahr der Oszillation die Konvergenz erschwert wird. Der folgende Ansatz reduziert das Momentum und damit die Schrittweite in steilen Passagen. Die jeweilige Situation

wird erkannt, indem den vorhergegangenen Fehleränderungen eine gewisse Bedeutung bei der Berechnung der aktuellen Gewichtsveränderung eingeräumt wird

$$I^{neu} = \alpha I^{alt} + (1 - \alpha) \frac{\partial \varepsilon^{alt}}{\partial \omega_{ij}^k} \quad (3.11)$$

$$\Rightarrow \omega_{ij}^{k, neu} = \omega_{ij}^{k, alt} - \eta * I^{neu} \frac{\partial \varepsilon}{\partial \omega_{ij}^k} \quad (3.12)$$

Günstige Werte für α sind 0,8 bis 0,95.

Sequentielles Training nutzt die mathematische Ableitung des Quadrates des Ausgabefehlers nach jedem einzelnen Gewicht. Diese wird dann entgegen der Richtung der Ableitung korrigiert, um den gesamten Fehler der Ausgabe zu reduzieren. Dieser Vorgang wird mit jedem Datensatz $\vec{x}, \vec{y}_{Wunsch}$ der Trainingsdaten wiederholt. Der Erfolg dieses Algorithmus ist stochastisch nachgewiesen und generiert stabile Netze, wenn die Trainingsparameter richtig gewählt wurden.

3.4.1.1.3 Mutation

Ein weiterer Ansatz besteht darin, bei der Neuberechnung zufällige Änderungen hinzuzufügen. Solche stochastischen Änderungen können ebenfalls nützlich sein, erreichte lokale Minima wieder zu verlassen. Ob ein solcher Ansatz stabil ist, hängt von der Häufigkeit (Wahrscheinlichkeit) und der Größe der Mutation ab.

3.4.1.2 **Batch Training**

Ein weiterer Ansatz verzichtet auf die zufällige Auswahl der Datensätze. Stattdessen wird die Fehleränderung (Ableitung des Fehlers nach der Variation der Größe der Gewichte) unter Berücksichtigung aller Datensätze ermittelt.

$$\frac{\partial \xi}{\partial \omega_{ij}^k} = \frac{1}{S} \sum_{p=1}^S \frac{\partial \varepsilon(\vec{x}_p, \vec{y}_{Wunsch_p}, \vec{w})}{\partial \omega_{ij}^k} \quad (3.13)$$

Hierbei ist ξ der mittlere Fehler des gesamten Trainingsdatensätze und S die Anzahl der Datensätze $\vec{x}, \vec{y}_{Wunsch}$. Ziel des Trainings ist, ξ zu minimieren. Die Probleme und Lösungsansätze für lokale Minima gelten hier genauso wie beim sequenziellen Training in Abschnitt 3.4.1.1, S. 20. Dem Nachteil des größeren Rechenaufwandes eines einzelnen Optimierungsschrittes steht eine geringere Anzahl von Wiederholungen für die Erreichung des Fehlerminimums gegenüber.

3.4.2 Training von dynamischen Netzen

Der Vorteil von dynamischen (rückgekoppelten oder auch recurrent (RC)) Netzen ist die Möglichkeit, damit dynamische Systeme zu beschreiben (vergl. Abschnitt 3.2.2). Die Herausforderung dabei ist aber, dass diese Dynamik auch während des Trainings präsent ist. Das heißt, die Ausgabe des Systems hängt nicht nur von den Eingabedaten ab, sondern auch von der Zeit. Somit kann ein solches System auch beim Training die für dynamische Systeme typischen Zustände einnehmen: Aufschwingen des Systems in instabile Zustände, stabiles Schwingen und asymptotisch gedämpftes Schwingen. In der Trainingshase ist der letzte Fall der gewünschte, um das Training erfolgreich durchführen zu können.

Das Verhalten von RC Systemen ist mathematisch sehr schwer zu erfassen. Grundsätzlich kann ein dynamisches (zeitlich abhängiges) System folgendermaßen beschrieben werden [4]:

$$\frac{d\vec{x}}{dt} = f(\vec{x}, \vec{u}, t) \quad (3.14)$$

Hierin ist \vec{x} der Vektor, welcher den Zustand des Systems beschreibt, \vec{u} ist der Vektor der Eingangsdaten und t ist die Zeit. Die Funktion f beschreibt die Abhängigkeit der zeitlichen Änderung des Zustands von den Eingangsdaten, der Zeit und dem Zustand selbst. f kann eine lineare oder nicht-lineare Funktion sein. Für lineare Funktionen existieren eine ganze Reihe von Lösungsansätzen für deren Bestimmung [5].

Im Falle von nicht-linearen Funktionen stellt sich der Fall aber schwieriger dar. Zunächst ist in der Regel nicht klar, welche Klasse von Funktionen sich hinter f verbergen kann (trigonometrische Funktionen, Exponentialfunktionen, Polynome etc.). Reine Formen dieser Funktionen sind ohnehin kaum zu erwarten. Dies gilt insbesondere bei multi-input/multi-output Systeme.

Ein Lösungsansatz geht von der Annahme aus, dass die Funktion f zeit-invariant ist. Das heißt, die zeitliche Änderung des Systems hängt nur vom Zustand des Systems und den Eingabedaten ab, nicht aber von der Zeit selbst. Dies wird auch als Markov-Bedingung bezeichnet. Anders ausgedrückt bedeutet dies: Der Zustand des Systems nach dem nächsten Zeitschritt hängt nur vom aktuellen Zustand des Systems ab und nicht von vorhergehenden ab. Es spielt also keine Rolle, wie das System in den aktuellen Zustand gekommen ist. Dieses Verhalten trifft zumindest näherungsweise für viele technische Anwendungen zu.

Ziel ist nun, die Funktion f durch eine Näherung zu beschreiben. Hierzu wird Gleichung (3.18) zunächst diskretisiert, wobei t_s die Abtastzeit ist.

$$\frac{\vec{x}(t) - \vec{x}(t - t_s)}{t_s} = f(\vec{x}(t - t_s), \vec{u}(t)) \quad (3.15)$$

oder äquivalent, wobei mit n der n -te Zeitschritt gemeint ist.

$$\vec{x}[n] = \vec{x}[n - 1] + t_s \cdot f(\vec{x}[n - 1], \vec{u}[n]) \quad (3.16)$$

Der Term rechts vom Gleichheitszeichen kann durch eine ANN-Funktion f_{ANN} beschrieben werden. Damit lässt sich der Zusammenhang folgendermaßen beschreiben

$$\vec{x}[n] = f_{ANN}(\vec{x}[n - 1], \vec{u}[n]) \quad (3.17)$$

Das bedeutet, dass ein dynamisches System dadurch simuliert werden kann, dass eine einfache Feed-Forward Topologie mit einer Rückkopplung versehen wird. Diese wurde bereits in Abschnitt 3.2.2 beschrieben.

Damit kann nun auch dieses RC-Netz mit den Methoden die für FF Netze beschrieben wurden trainiert werden. Es ist lediglich zu beachten, dass zusätzlich zu den externen Eingabedaten auch Ergebnisse der ANN-Berechnungen aus vorhergehenden Rechenschritten als Eingabedaten für das ANN-Netz zu berücksichtigen sind.

Für das Training wird sozusagen eine Entkopplung des Netzes von der Zeit realisiert. Man spricht auch von einem „unfolding in time“ des Netzes.

3.4.3 Nicht überwachtes Lernen

Selbstlernende Algorithmen werden hauptsächlich für Datenanalyse und Mustererkennung genutzt. Im Gegensatz zum überwachten Training existiert kein Referenzwert, mit dem Ausgabedaten verglichen werden könnten. Solche Algorithmen können zur Datenvorverarbeitung genutzt werden, wenn große Datenmengen zu verarbeiten sind. Sie können dann die Datenvolumen reduzieren und unwichtige Daten aussondern.

3.4.3.1 Hebbs selbstlernende Algorithmen

Diese Datentransformation und Reduktion wie Sie mit der Hauptkomponentenanalyse (PCA) realisiert wird kann auch mit Hilfe von Neuronalen Netzwerken erreicht werden (Hebbs selbstlernende Topologie [2]). Hierzu wird eine Topologie wie in Abbildung 9 dargestellt aufgebaut. In den Neuronen N werden Linearkombinationen der Eingabewerte x generiert. Die Übertragungsfunktion zur Ermittlung ist die Identität, das heißt, das Ergebnis der Linearkombination wird ohne

weiter Veränderung an die Ausgabe y übergeben. Diese Ausgabe wird nun mit den erwarteten Ausgabewerten aus den Trainingsdaten verglichen und die Gewichte ω_{ij} so angepasst, dass die Abweichung minimiert wird. Die Berechnung der Gewichtsveränderungen im Netz folgt folgender Gleichung.

$$\Delta\omega_{ji}(n) = \eta \left[y_j(n) \cdot x_i(n) - y_j(n) \cdot \sum_{k=1}^j \omega_{ki}(n) \cdot y_k(n) \right] \quad (3.18)$$

Dies stellt eine verallgemeinerte und ursprünglich von Hebb postulierten Lernregel [6] dar.

Die Zahl der Neuronen N wird solange reduziert, bis die maximal zulässige Abweichung nicht überschritten ist. Auf diese Weise wird eine Linearkombination gefunden, welche in Ihrer Dimension reduziert ist, aber trotzdem die wesentlichen Einflüsse repräsentiert. Das Ergebnis entspricht dem der Hauptkomponentenanalyse.

3.4.3.2 Self-Organizing Maps

Die PCA-Analyse und damit auch Hebbs Topologie ist in der Lage, linear separierbare Datenräume in statistisch komplett unabhängige Datensätze zu überführen. Ist diese Voraussetzung nicht gegeben, so werden die Datensätze nur dekorelliert, das heißt die Abhängigkeit wird reduziert, aber nicht aufgehoben.




Abbildung 9: Implementierung einer Hauptkomponentenanalyse mit Hilfe eines neuronalen Netzwerkes

Eine weitergehende Methode der Neuronalen Netzwerke hilft, dieses Problem zu lösen. Dieser Ansatz nennt sich Self-Organizing Maps (SOM) [2]. Dieser Ansatz wird hauptsächlich genutzt, um einen Datenraum auf die Dimension 2 zu reduzieren. Im weiteren Projektverlauf soll geklärt werden, ob ein solcher Ansatz zielführend sein kann.

3.5 Schlussfolgerungen

Bei der Analyse geeigneter Topologien konnten zwei Topologien identifiziert werden, welche für die Lösung der Aufgaben im Projekt ANNsolar besonders gut geeignet scheinen. Dies ist die Feed-Forward Topologie für Probleme, welche kein dynamisches Verhalten erfordern. Für dynamische Fragestellungen konnte eine einfache Recurrent Topologie identifiziert werden, welche aus einem Feed-Forward Kern besteht, der durch eine einfache Rückkopplung zur Recurrent Topologie wird.

Für den erfolgreichen Einsatz der neuronalen Netzwerke ist eine Datenvorverarbeitung nützlich. Hierfür bieten sich klassische Methoden wie die Hauptkomponentenanalyse an. Diese kann auch in Form eines Ansatzes mit neuronalen Netzen realisiert werden.

Für das Training von ANN Netzen existiert eine Vielzahl verschiedener Ansätze. Die Ansätze, welche nach aktuellem Kenntnisstand für die Aufgabe im Projekt ANNsolar geeignet erscheinen, wurden vorgestellt.

Mehrere der präsentierten Topologien und Trainingsalgorithmen wurden erfolgreich implementiert und getestet.

4 Regelungskonzept

4.1 Anforderungen an ein ANN-Regelungskonzept

Jedes Gebäudebeheizungssystem benötigt eine Regelung zur Sicherstellung der gewünschten Raumtemperatur. Sind mehrere Wärmeerzeuger Teil eines solchen Systems, wachsen die Anforderungen an die Regelung. Diese Situation tritt immer häufiger auf, weil mit der Kombination fossiler und erneuerbarer Wärmeerzeuger die Reduzierung des Verbrauchs fossiler Energien angestrebt wird. In konventionellen Heizungssystemen wird der Energiefluss gesteuert. Bei der Nutzung solarer Energie hingegen ist die Energiequelle, die Sonne, nicht steuerbar. In solchen Systemen kommen daher Wärmespeicher zum Einsatz, was den Regelungsaufwand nochmals erhöht.




Abbildung 10: Referenz-Solaranlage für die kombinierte Heizung und Warmwassererzeugung mit Kollektor, Wärmetauscher für die Warmwasserbereiter konventionellem Wärmeerzeuger und Wärmespeicher

Ziel der Regelung ist, zum einen komfortable Raumbedingungen für den Nutzer zu schaffen und zum anderen den Verbrauch fossiler Energien zu minimieren. Weitere Anforderungen an die Regelung sind eine intuitive Bedienbarkeit für den Nutzer sowie die Erkennung möglicher Fehler beim Betrieb der Anlage und dies zu möglichst geringen Investitions- und Betriebskosten.

Ziel des Projektes ANNsolar ist, genau diese Anforderungen in noch besserer Weise zu erfüllen, als dies mit heutiger Reglertechnologie möglich ist. Erreicht werden soll dieses Ziel durch die Nutzung der Methodik künstlicher neuronale Netzwerke.

4.1.1 Hydraulik einer typischen solarthermische Anlage zur kombinierten Heizung und Warmwassererzeugung

Für die Entwicklung des neuen Regelungskonzeptes und dessen Validierung soll ein Referenzsystem definiert werden. Dieses Referenzsystem, basierend auf dem Layout einer typischen solarthermischen Anlage zur kombinierten Heizung und Warmwassererzeugung, ist in Abbildung 10 dargestellt. Sie besteht aus einem Speicher, einem Kollektorfeld, einem konventionellen Wärmeerzeuger, einem Wärmetauscher zur Warmwassererzeugung und einer sogenannten Frischwasserstation. Mit dem Buchstaben P sind die Umwälzpumpen gekennzeichnet, welche zum Betrieb nötig sind. T_1 ist die Vorlauftemperatur des Kollektorfeldes, T_{VZ} die Vorlauftemperatur des Heizkreises und T_2 ist die Temperatur des Speichers.

Wenn Solarstrahlung auf den Kollektor trifft, erhöht sich seine Temperatur. Sobald diese Temperatur um einen gewissen Betrag höher ist als die Temperatur T_2 des Speichers im unteren Bereich, so wird die Pumpe P1 eingeschaltet. Die Pumpe läuft so lange dieses Kriterium erfüllt ist oder bis eine Maximaltemperatur des Speichers erreicht ist. Das Einschaltkriterium für den konventionellen Wärmeerzeuger wird durch die für die Beheizung und Warmwassererzeugung notwendige Mindesttemperatur des Speichers bestimmt. Die Regelung der Frischwasserstation soll hier nicht weiter berücksichtigt werden.

Betrachtet man die heutigen Ansätze der Regelung, so ergibt sich eine Reihe von Fragen wie zum Beispiel:

- Was ist die optimale Einschaltbedingung für den Solarkreis? Was ist die optimale Drehzahl der Pumpe?
- Was ist das optimale Einschaltkriterium für die konventionellen Wärmeerzeuger? Kann man möglicherweise auf eine konventionelle Nachheizung verzichten, weil aufgrund der Randbedingungen keine wesentliche Abkühlung des Gebäudes zu erwarten ist?
- Gibt es hierfür eine einfache Möglichkeit die Temperaturänderung des Gebäudes zu prognostizieren?
- Wie kann man mit möglichst geringem Aufwand eine optimale Heizkurve ermitteln?

Das Projekt ANNsolar versucht Antworten auf diese und andere Fragen zu geben. Der Ansatz hierfür ist die Methode der künstlichen Neuronalen Netzwerke.

4.1.2 Funktionalitäten und Potenziale neuronaler Netze für die Anwendung in der Solarthermie

Die Vorteile der neuronalen Netzwerke ergeben sich durch die andere Art der Programmierung. Für verschiedene Anwendungen baut man sehr ähnliche Netzwerkstrukturen auf. Diese werden auf der Reglerhardware implementiert. Die eigentliche Funktionalität der Regelung entsteht bei ausschließlicher Nutzung von ANN allerdings nicht wie bei der konventionellen Regelung durch Anpassung von Parametern, sondern durch einen Trainings- oder Lernprozess. Dadurch vereinfacht sich die Programmierung, welches offensichtlich Vorteile bezüglich Aufwand und Fehlerwahrscheinlichkeit bietet und damit Kostenvorteile erzeugt.

Außerdem können mit dieser Methodik wesentlich einfacher komplexe Regelungsstrategien realisiert werden, welche eine Steigerung der Energieeffizienz ermöglichen. Dazu gehören zum Beispiel die Möglichkeit selbstlernende Algorithmen zu schaffen, Prognosemöglichkeiten bezüglich Wetter und Nutzerverhalten zu berücksichtigen, sowie die Regelung von Solaranlage, Nachhei-

zung und Heizkreis stärker zu integrieren. Damit bieten sich auch ganz neue Möglichkeiten der Regelungsoptimierung in Hinblick auf Energieeffizienz und Kundenkomfort.

Es soll an dieser Stelle allerdings darauf hingewiesen werden, dass im vorliegenden Fall die Regelung nicht ausschließlich auf ANN-Strukturen beruht. Die Gründe hierfür werden zu einem späteren Zeitpunkt erläutert.

Im Folgenden sollen nun zunächst die technischen Potenziale beschrieben werden.

4.1.2.1 Heizkreis

Konventionelle Heizungssysteme arbeiten mit einer sogenannten Heizkurve, welche die Vorlauf-temperatur in Abhängigkeit von der Außentemperatur steuert. Die energieeffiziente Einstellung dieser Kurve erfordert einiges an Aufwand und wird deshalb vermutlich in der Mehrzahl der Fälle nicht ausreichend gut durchgeführt. Außerdem hängt die optimale Vorlauf-temperatur nicht nur von der Außentemperatur sondern auch von der solaren Einstrahlung und den inneren thermischen Lasten ab. Diese wird von konventionellen Regelungen in der Regel nicht berücksichtigt. Für diesen Fall liefert ANN einen Ansatz mit dem eine optimale Heizkurve automatisch generiert werden kann.

Analog zu ANN-Regelung der Drehzahl der Solarpumpe (Abschnitt 4.1.2.2) kann ANN auch zum stabileren Betrieb der Mischventile des Heizkreises eingesetzt werden.

Eine weitere Optimierungsmöglichkeit besteht darin, frühzeitig vor dem Beginn der Nachtab-senkung bzw. der morgendlichen Aufheizung die Vorlauf-temperatur des Heizkreises abzusenken bzw. anzuheben. Auch dies ist sinnvoller Weise mit einem lernenden ANN-Algorithmus zu realisieren, welcher in der Lage ist, die richtigen variablen Vorlaufzeiten in Abhängigkeit von Gebäude um Außentemperatur zu ermitteln.

4.1.2.2 Solarkreis und Wärmespeicher

Für die Effizienz eines Kollektors ist die Temperaturdifferenz zwischen Außentemperatur und Fluid-temperatur entscheidend. Damit müsste das Ziel zunächst sein, den Kollektor immer auf möglichst niedrigem Temperaturniveau zu betreiben. Auf der anderen Seite wird aber je nach Heiz- und Wärmebedarf des Gebäudes eine gewisse Betriebstemperatur benötigt. Dazwischen steht der thermische Speicher, der je nach Ladezustand unterschiedliche Temperaturniveaus zur Verfügung stellen kann. Es stellt sich nun die Frage, ob es möglicherweise sinnvoll wäre, die Effizienz des Solarkreises zu reduzieren und den Solarkreis bei einer höheren Temperatur zu betreiben um auf der anderen Seite das Nachheizen mit einem konventionellen Wärmeerzeuger zu verhindern. Offensichtlich ist, dass dieser Konflikt nicht einfach im Sinne einer optimalen Energieeffizienz zu lösen

ist, weil sowohl saisonale Einflüsse, individuelle Randbedingungen der Gebäude sowie der jeweils temporäre Zustand des Systems eine Rolle spielen. Konventionelle Regelungen sind daher normalerweise nicht in der Lage, dieses Optimierungspotenzial zu realisieren. Künstliche neuronale Netzwerke können aber dieses Optimierungsproblem lösen.

Ein weiterer Ansatz, ANN nützlich einzusetzen besteht darin, das Gebäude als zusätzliche thermische Speichermasse einzusetzen. Dabei wird unter bestimmten Randbedingungen eine leichte Steigerung der Gebäudetemperatur angestrebt, sodass das Gebäude aufgrund seiner thermischen Kapazität als zusätzlicher Wärmespeicher genutzt wird. Entscheidend hierbei ist aber, dass diese Temperaturerhöhung nur dann stattfindet, wenn zum einen im Tagesverlauf keine Überhitzung des Gebäudes zu erwarten ist, zum anderen aber auch tatsächlich ausreichend Solarwärme zur Verfügung steht, um diese im Gebäude speichern zu können.

Je nach Rohrleitungslänge, Kollektorfläche und Wärmeübertragergröße wird im Feld beobachtet, dass die konventionelle Temperaturdifferenzregelung der Pumpendrehzahl zu relativ instabilen Drehzahlen führt. Folge ist eine ständig wechselnde Pumpendrehzahl, auch bei stabilen Einstrahlungsbedingungen. Entsprechend schwankt auch die Vorlauftemperatur des Solarkreises und liegt damit nicht immer im optimalen Betriebsbereich. Um diese Problem zu lösen, müssten in einem konventionellen System die dynamischen Parameter der Drehzahlregelung an das System angepasst werden. Diese sind jedoch nicht nur system- sondern auch zustandsabhängig. Somit wird es bei konventionellen Systemen in der Praxis kaum möglich sein, eine entsprechende Parametrisierung mit vertretbarem Aufwand zu realisieren. Ein selbstlernender ANN-Ansatz schafft hier die Möglichkeit anlagenspezifisch und zeitabhängig die optimalen Parameter automatisch zu identifizieren.

Auch bei der Vermeidung von Stagnation kann der ANN-Ansatz hilfreich unterstützen. ANN kann die Speicherbeladung im Tagesverlauf prognostizieren. Es ist daher frühzeitig möglich, eine Komplettbeladung des Speichers und damit eine Stagnationsphase vorherzusagen. Entsprechend kann die Anlage temporär in einem ineffizienten Modus betrieben werden (Anhebung der Vorlauftemperatur). Dies führt zur Verminderung von Stagnationszeiten oder hilft diese sogar ganz zu vermeiden.

4.1.2.3 Nachheizung

Optimierungspotenziale sind hier gegeben durch eine sinnvolle Speicherbewirtschaftung. Bei real existierenden Systemen ist immer wieder zu beobachten, dass der Speicher konventionell nachgeheizt wird, obwohl dies überhaupt nicht notwendig wäre. So macht eine Nachheizung des Speichers keinen Sinn, wenn zum Beispiel in absehbarer Zeit die Absenkung der Vorlauftemperatur wegen Nachtabsenkung ansteht. Für konventionelle Systeme ist es aber aufgrund sehr unter-

schiedlicher Randbedingungen wie Außentemperatur und Gebäudeträgheit kaum möglich, mit vertretbarem Aufwand sicher abzuschätzen, wie lange die aktuell gespeicherte Wärme noch ausreicht, um die Temperatur im Gebäude noch zu halten. Auch hier kann ANN das Problem lösen, weil es in der Lage ist, sich der jeweiligen individuellen Situation anzupassen.

4.1.2.4 Wetterprognose

ANN ist auch in der Lage eine lokale Wetterprognose zu erstellen anhand derer der Betrieb einer solarthermischen Kombianlage weiter optimiert werden kann. Alternativ hierzu bietet sich natürlich eine Wetterprognose über das Internet an.

4.1.2.5 Fehlerprognose

ANN ist in der Lage, bestimmte Muster zu erkennen und zu klassifizieren. Dadurch ist es möglich, auch das Muster „korrekter Betrieb“ zu lernen und Abweichung hiervon zu detektieren. ANN könnte somit spontane Abweichungen von einer typischen gebäudespezifischen Betriebsweise wie zum Beispiel Pumpenfehlverhalten, Fehler von Temperatursensoren oder Zustände wie „Offenes Fenster“ identifizieren. Schwierig für ANN ist allerdings die Entdeckung sich graduell entwickelnder Abweichungen wie zum Beispiel Verkalkung von Wärmetauschern. Dies ist besonders dann der Fall, wenn das Training mit individuellen Anlagendaten stattfindet, bei denen nicht bekannt ist, mit welcher Qualität die Anlage normalerweise läuft.

4.1.2.6 Anwesenheitserkennung

ANN Algorithmen sind in der Lage, mit einer guten Genauigkeit Anwesenheitsmuster von Bewohnern zu erlernen. Hierzu werden zum Beispiel die Ein und Ausschaltung von elektrischen Geräten, Lichtbetätigungen, Warm- und Kaltwasserverbrauch oder auch Informationen von Bewegungssensoren als Eingabedaten erfasst. Das System ist hierbei in der Lage, insbesondere auch den Einfluß auf den Energieverbrauch zu identifizieren. Der Aufwand, eine solche Regelung zu implementieren, erscheint allerdings zum jetzigen Zeitpunkt sehr hoch.

4.1.3 Priorisierung der ANN Funktionalitäten für solarthermische Kombianlagen

Um eine klare Fokussierung des Projektes zu gewährleisten, wurde im Rahmen eines Workshops mit den Industriepartnern eine Priorisierung der Themen vorgenommen. Ziel war, die ANN-Funktionalitäten zu identifizieren, die gemäß den Kriterien Technische Relevanz, Potenzial zur Kostensenkung und Endkundenattraktivität die höchste Priorität haben.

Damit werden im Projekt ANNsolar folgende ANN-Ansätze weiterverfolgt:

1. Automatische Ermittlung der Heizkurve
2. Optimale Regelung der Nachheizung im Zusammenspiel zwischen erwartetem Solarertrag und Energieverbrauch
3. Optimale An- und Ausschaltzeit des Heizkreises im Zusammenhang mit Nachtabenkung
4. Nutzung der thermischen Speicherkapazität des Hauses

4.2 ANN-Regelungsansatz

Die Regelung der Kreisläufe der in Abbildung 11 dargestellten hydraulischen Anlage soll mit Hilfe von künstlichen neuronalen Netzen (ANN) effizienter betrieben werden. Die ANN-Regelung soll im vorliegenden Fall folgende Regelungsfunktionen übernehmen.

1. Sollwertermittlung der Vorlauftemperatur des Heizkreises ($T_{f,tg}$).
2. Regelung der Zuschaltung des Pelletbrenners (an/aus, Signal $S_b = 0$ oder 100%,
 S_b entspricht 1A11 in Abbildung 11).

Die restliche Steuerung (Pumpendrehzahlen, etc.) entspricht im Wesentlichen der in der realen Testanlage verbauten konventionellen Regelung.

Das Regelungskonzept basiert auf der Prognose der Entwicklung der Raumtemperatur im Gebäude und des Speicherladezustandes durch 2 neuronale Netze. Die prinzipielle Funktionsweise beider Netze ist identisch. Prognose-Werte für die Zukunft werden durch das ANN ermittelt. Dafür benötigt das ANN eine ganze Reihe von Input Daten. Diese werden zum Teil vorgegeben (z.B. Vorlauf Solltemperatur), zum Teil stammen diese aus Wettervorhersage (z.B. Umgebungstemperatur und Solarstrahlung), zum Teil werden diese aus der Fortschreibung des aktuellen Status generiert (z.B. Oberflächentemperatur des Kaminofens). Dieses Prinzip soll zunächst allgemeingültig erläutert werden.

Ein statisches ANN berechnet Outputs $\vec{y}(t)$ aus Inputs $\vec{x}(t)$ zur Zeit t . Im dynamischen Fall werden die Outputs $\vec{y}(t)$ aus Inputs $\vec{x}(t)$ und den Outputs aus dem vorherigen Zeitschritt $\vec{y}(t - t_s)$ berechnet.




Abbildung 11: Kreisläufe der hydraulischen Anlage

Im Allgemeinen ist \vec{x} der Vektor der Inputvariablen mit Komponenten x_k , ($k = 1, \dots, K$) und \vec{y} der Vektor der Outputvariablen mit Komponenten y_m , ($m = 1, \dots, M$). Ein gegebenes ANN arbeitet auf einem Zeitraster mit diskreten Zeitpunkten $t_n = t_0 + n t_s$. Zu einem bestimmten Zeitpunkt t_n haben die Zustandsvektoren die Werte $\vec{x}[n] := \vec{x}(t_n)$ und $\vec{y}[n] := \vec{y}(t_n)$ mit Komponenten $x_k[n] := x_k(t_n)$ und $y_m[n] := y_m(t_n)$.

Zur Berechnung der Outputs zum Zeitpunkt t_n müssen bekannt sein:

- die Inputvariablen $\vec{x}[n]$ zum selben Zeitpunkt
- und im dynamischen Fall auch die Outputvariablen $\vec{y}[n - 1]$ zum vorherigen Zeitpunkt $t_n - t_s$

Die Outputvariablen zum Zeitpunkt t_n werden durch das ANN als multidimensionale Funktion \vec{g} der bekannten Werte berechnet:

Für ein statisches System:

$$\vec{y}(t_n) = \vec{g}[x_1(t_n), x_2(t_n), \dots, x_K(t_n)] \quad (4.1)$$

oder kurz

$$\vec{y}[n] = \vec{g}[\vec{x}[n]] \quad (4.2)$$

Für ein dynamisches System:

$$\vec{y}[n] = \vec{g}[\vec{x}[n], \vec{y}[n - 1]] \quad (4.3)$$

D.h. die Outputs des letzten Zeitschritts werden als zusätzliche Inputs für den nächsten Zeitschritt verwendet.

Die ANN-Funktion \vec{g} ist im Allgemeinen nicht analytisch und kann nicht isoliert extrahiert werden. Sie ist durch die Struktur und die Gewichtsmatrizen des ANN gegeben.

Im Regelungsprogramm werden die ANN prinzipiell folgendermaßen eingesetzt (Die konkrete Beschreibung der Umsetzung erfolgt in den Abschnitten 5.2.5 und 5.2.8):

Die entsprechende Steuerungseinheit wird zum Zeitpunkt t_0 aktiviert. Das Ziel ist es, die Output-Werte für die nächsten N Zeitschritte (t_1, \dots, t_N) zu berechnen (d.h. es sollen $\vec{y}[1], \dots, \vec{y}[N]$ berech-

net werden). Der gesamte Prognosezeitraum wird mit $t_{prog} = N \cdot t_s = t_N - t_0$ bezeichnet. Zum aktuellen Stand nutzen wir ausschließlich dynamische ANN. Dementsprechend werden benötigt:

- Die Inputvariablen zu jedem Zeitpunkt ($\vec{x}[1], \dots, \vec{x}[N]$)
- Die Outputvariablen zum Startzeitpunkt ($\vec{y}[0]$)

Die Variablen $\vec{y}[n] = \vec{g}[\vec{x}[n], \vec{y}[n-1], \dots]$ werden rekursiv für $n = 1, \dots, N$ berechnet.

Da $\vec{x}[n]$ für $n = 1, \dots, N$ (Zukunft!) benötigt werden, müssen Vorhersagen für diese Werte gemacht werden. In unseren Fällen werden diese Vorhersagen aus Zeit und Datum, Wetterprognosedaten und anderen Annahmen abgeleitet. Für die nächsten N Zeitschritte liegt nun eine Reihe von Werten für jede Input-Vektorkomponente x_k vor. Diese Zeitreihe wird mit $R(x_k) := \{x_k[1], x_k[2], \dots, x_k[N]\}$ bezeichnet. Die einzelnen Werte in $R(x_k)$ werden im Allgemeinen nicht gleich sein (ein Beispiel ergibt sich, wenn man die Uhrzeit, bzw. die Minuten des Tages als Inputvariable verwendet).

Die verwendeten Algorithmen verlaufen prinzipiell folgendermaßen:

- Die Werte $\vec{y}[0]$ werden zum Zeitpunkt t_0 gemessen.
- Alle Zeitreihen $R(x_k)$ [$k = 1, \dots, K$] werden für die nächsten N Zeitschritte gesetzt.
- Die Outputs $\vec{y}[n]$ werden für die nächsten N Zeitschritte berechnet.
- Die Outputs $\vec{y}[n]$ werden ausgewertet (die Art und Weise wird konkret in den folgenden Abschnitten beschrieben).
- Falls definierte Bedingungen nicht erfüllt sind, werden diejenigen Input-Zeitreihen $R(x_k)$, die wir aktiv steuern können, systematisch verändert bis die festgelegten Bedingungen erfüllt sind, bzw. nicht erfüllt werden können. Im jetzigen Ansatz wird dabei nur jeweils ein bestimmter Parameter $x_p(t)$ verändert (und damit alle Zeitreihen $R(x_{p*})$, die von x_p abhängen). Alle anderen Zeitreihen verbleiben, wie beim ersten „Versuch“. In der Heizkreisregelung ist x_p beispielsweise die Vorlaufsolltemperatur ($T_{f,tg}$), die schrittweise erhöht wird, bis gewählte Bedingungen für die Raumtemperatur erfüllt sind. Der Parameter x_p wird dementsprechend aktiv geregelt.

5 Entwicklung des ANN-basierten Regelungsprogramms

Das entwickelte Regelungsprogramm basiert auf einer ANN-Prognosesoftware, welche in der Lage ist, für die Regelung des Heizungssystems Prognosen über Raumtemperaturentwicklung und Speicherladezustand zu berechnen. In einem ersten Schritt wurde daher eine ANN-Prognosesoftware entwickelt, welche in der Lage ist aus beliebigen Input und Output Daten ANN Netze zu generieren, mit denen die Zusammenhänge zwischen diesen Werten in einem black-box Modell abgebildet werden können. Diese trägt den Namen WinANN.

Im darauf folgenden Abschnitt wird dargestellt, wie mit WinANN ein Regelungsprogramm realisiert werden kann. Dem schließt sich die Beschreibung einiger spezieller Problemlösungen sowie die Darlegung der notwendigen Rechnerleistung und Speicherkapazität an.

5.1 ANN-Prognose Software WinANN

5.1.1 Anforderungen an die ANN Software

Die größten Herausforderungen für die zu entwickelnde ANN Software ergeben sich bei deren Nutzung sowohl in der Phase der virtuellen als auch insbesondere in der Phase der experimentellen Tests. Hierbei ist eine sehr stabile und robuste Software erforderlich, welche reibungslos über einen langen Zeitraum arbeiten kann. Während der experimentellen Testphase, welche mehrere Monate dauerte, musste es möglich sein, alle Zustände des Systems zu erfassen und zu sichern. Nach einem Abbruch mit anschließender Systemänderung, muss das System bei Bedarf wieder in der Lage sein, beginnend vom vor dem Abbruch herrschenden Zustand seinen Betrieb fortzusetzen.

Außerdem muss es möglich sein auch während des Betriebs mit dem System zu interagieren. Dies bedeutet, dass sogenanntes multi-threading¹ eine wesentliche Funktionalität der Software sein musste. Diese Interaktion beinhaltet sowohl die Aufzeichnung von Zuständen als auch parallele Testläufe für die Analyse und Bewertung von Leistungsfähigkeit sowie Fehlerermittlung.

¹ multi-threading bedeutet das gleichzeitige Abarbeiten mehrerer Threads (Ausführungsstränge) innerhalb eines einzelnen Prozesses. Im Gegensatz zum Multitasking, bei dem mehrere unabhängige Programme voneinander abgeschottet quasi-gleichzeitig ausgeführt werden, sind die Threads eines Anwendungsprogramms nicht voneinander abgeschottet.

Darüber hinaus erfordert die Nutzung im Forschungsprojekt ANNsolar eine hohe Flexibilität des ANN-codes. Die beste Struktur mit den effizientesten Algorithmen sollte erarbeitet werden. Dies erforderte das Testen einer großen Anzahl von unterschiedlichen ANN-Strukturen, Topologien und ANN Netzwerk Größen. Außerdem wurden unterschiedliche Trainingsmethoden analysiert. Untersuchungen zu Beginn des Projektes haben gezeigt, dass für die Beschreibung eines Solaren Heizungssystems eine Kombination aus klassischen Methoden und ANN-Methoden der vielversprechendste Ansatz ist. Hierbei sind klassische Methoden besser geeignet, lineare Zusammenhänge zu beschreiben, nicht-lineare werden besser durch ANN-Methoden abgebildet. Da ein solares Heizungssystem sowohl lineares als auch nicht-lineares Verhalten zeigt, ist es naheliegend, eine Kombination von klassischen und ANN-Methoden zu verwenden. Auch hierfür war eine Vielzahl an Tests mit entsprechenden Anforderungen erforderlich. Dies erforderte ebenfalls eine hohe Flexibilität des ANN-codes.

Eine weitere wichtige Anforderung an den ANN-code ist die Fähigkeit, den Zustand und die Veränderungen des ANN Netzes jederzeit nachverfolgen zu können. Nur so ist es möglich, Fehler und Optimierungsmöglichkeiten in der ANN Struktur zu identifizieren und zu beheben. Beispielsweise ist es möglich, dass beim Training der Optimierungsprozess des Netzes in einem lokalen Optimum hängen bleibt oder kein Optimum findet. Auch sogenanntes „Overfitting“ kann auftreten. Solche Fälle können nur erkannt werden, wenn eine real-time Verfolgung des Netzzustandes während des Trainings erfolgt.

Ein Charakteristikum der Regelung eines gesamten Gebäudebeheizungssystems besteht im großen Umfang der Ein- und Ausgangsgrößen. Aktuelle Regelungen verarbeiten zum Teil mehr als 20 Eingangssignale. Hierzu zählen zum Beispiel Temperaturen der Wohnräume, Wärmespeicher, Kollektoren, Wärmeerzeuger, Volumenströme der verschiedenen Kreisläufe usw. Darüber hinaus spielen auch nicht-anlagenspezifische Eingangssignale wie beispielsweise Uhrzeit, Datum oder auch Wettervorhersage eine wichtige Rolle.

Die Ausgangsgrößen des Regelungsmoduls umfassen unter anderem die Zieltemperaturen in verschiedenen Ebenen des Speichers, den Status des Zusatzwärmeerzeugers, die Pumpenzustände in den verschiedenen Kreisläufen, die Zieltemperatur des Heizkreisvorlaufs usw. In einem konventionellen Regelungssystem existieren verschiedene Regelungskreises, welche diese Ausgangssignale generieren.

Ein erster Ansatz eine solches Regelungssysteme mit ANN-Methoden umzusetzen ist, ein großes ANN Netz zu generieren, welches alle Inputsignale in Form eines Eingangsvektors empfängt und alle Ausgangssignale als einen einzigen Ausgangsvektor erzeugt. Die der ANN-Methode zugrunde liegende Mathematik erlaubt zumindest theoretisch einen solchen Ansatz solange die Größe des ANN-Netzes ausreichend groß ist. In der tatsächlichen Anwendung zeigt sich jedoch, dass die

damit verbunden hohen Anforderungen an Rechnerleistung und Speicherplatz eine andere Herangehensweise erforderlich machen. Darüber hinaus wurde auch im Sinne einer besseren Transparenz der Regelung und der damit verbundenen Vorteile bezüglich Qualitätssicherung und Kundenservice dieser Ansatz verworfen und eine niederschwelliger Nutzung der ANN Netze umgesetzt (Abschnitt 8).

Wie in Kapitel 5.5 noch gezeigt wird, erfordert die Vergrößerung des ANN-Netzes um den Faktor k je nach Algorithmus eine Erhöhung der Rechenleistung um den Faktor der Größenordnung k^2 oder sogar k^3 . Der notwendige Speicherplatz für einen Inputvektor der Dimension m beträgt bei manchen Algorithmen etwa m^3 . Für kleine Elektronikchips, wie sie häufig für die beschriebene Regelungsaufgabe genutzt werden, sind in der Regel 1 kbyte RAM verfügbar, 8 kbyte RAM jedoch kaum. Eine Minimierung der Größe der ANN-Netze ist daher sinnvoll, um möglichst kleine und kostengünstige Elektronikchips nutzen zu können.

Sofern Algorithmen angewendet werden sollen, welche eine Rechnerleistung proportional zu $m!$ erfordern, verschärft sich das genannte Problem nochmals erheblich. 10 Eingangssignale erfordern hierbei machbare 3,6 Mio arithmetische Operationen wo hingegen 20 Eingangssignale bereits 2,4 Milliarden arithmetische Operationen erfordern würden, was außerhalb der Möglichkeiten eines einfachen Chips liegt.

Eine weitere Schwierigkeit des großen Speicherplatzbedarfs ist die Erschwerung des Findens von Fehlern. Wenn in einem großen Netz das Ausgangssignal nicht den Erwartungen entspricht, ist es nachvollziehbar, dass die Fehlersuche sich schwieriger gestaltet als in einem kleinen Netz.

Um die genannten Schwierigkeiten zu verringern bez. zu vermeiden, ist es sinnvoll statt eines großen ANN-Netzwerkes mehrere kleine aufzubauen, die miteinander interagieren.

Es ist offensichtlich, dass die ANN Software mit der Hardware der Solaranlage kommunizieren muss. Außerdem musste eine Schnittstell zu Simulationsumgebungen wie DYMOLA oder TRANSYS realisiert werden, um virtuelle Tests durchzuführen. Entsprechend mussten geeignete Methoden zum synchronen Betrieb einer simulierten Anlage und der ANN Software ausgewählt werden. Hierfür wurden die zwei Methoden „network linking“ und „memory sharing“ als geeignet identifiziert. Im Falle des „network linking“ findet die Kommunikation über ein TCP/IP Protokoll statt.

Vorteil hierbei ist der hohe Standardisierungsgrad und die vom Betriebssystem unabhängige Betriebsweise. Network linking erlaubt die ANN Software auf einem Rechner und die Simulationssoftware auf einem zweiten Rechner laufen zu lassen. Beide Rechner können ggfs. auch auf un-

terschiedlichen Betriebssystemen laufen. Im Vergleich zu „memory sharing“ ist „network linking“ allerdings langsam.

„Memory sharing“ weist einen Teil des Rechner RAMs mehrfach Prozessen oder Softwares zu. Damit ist eine sehr schnelle Kommunikation zwischen der ANN Software und der Simulation möglich. Allerdings müssen beide Anwendungen auf ein und derselben Maschine laufen.

Tabelle 1 zeigt nochmals zusammenfassend die verschiedenen Anforderungen an die ANN Software.

5.1.2 Hauptstruktur und Komponenten der ANN Software

Für eine effiziente Realisierung der Software wird im Projekt die objektorientierte Programmiersprache C++ genutzt. Objektorientierte Programmierung ist ein Verfahren zur Strukturierung von Programmen, bei dem Programmlogik zusammen mit Zustandsinformationen (Datenstrukturen) in Einheiten, den Objekten, zusammengefasst werden. Sie bietet die Möglichkeit einer besseren Modularisierung der Programme, sowie einer höheren Wartbarkeit des Quellcodes, welche eine hohe Zeitersparnis beim Schreiben des Quellcodes mit sich bringt.

Wie zuvor erwähnt soll die Software mehrere ANN synchron oder parallel bearbeiten können. Dies beinhaltet jeweils die parallele Erstellung von Netzen, Anpassung der Netzwerkparameter, Netzwerktraining, Regelungsbetrieb des ANN sowie ggfs. die Löschung nicht notwendiger ANNs.

Tabelle 1: Funktionalitäten und Merkmale der ANN-Software

No	Kategorie	Merkmal/ Funktionalität	Beschreibung
1	File operations	allgemein	Ein klassisches Reglermodul mit verschiedenen Funktionen soll durch einen ANN Regelungsalgorithmus ersetzt werden. Das ANN-Netz soll aus mehreren kleinen Netzen bestehen, um die Anforderungen an die Hardware gering zu halten. Die Software muss in der Lage sein, ANN Netze zu generieren, zu trainieren und die verschiedenen Teilnetze zu verbinden.
2		Open Trainer Files	Trainingsdaten können sowohl während des Regelungsprozesses als auch in Form eines komplett vorliegenden Datensatzes erzeugt und genutzt werden. Open Trainer files erlaubt das Einlesen eines kompletten Trainingsdatensatzes.
3		Save ANNs	Sollte die Software abgebrochen werden, so müssen alle Zustände des ANN gespeichert werden
4		Open ANNs	Wenn die Software gestartet wird, muss der Zustand eines ANN aus einer vorherigen Sicherung geladen werden können.
5		Exit	Sicheres Schließen von Projekten und Software
6	Lineare Analyse	PCA	Hauptachsenanalyse (Principal Component Analysis) kann für die Reduzierung der Dimension des Datenraumes genutzt werden. Damit werden Anforderungen an Speicherplatz und Prozessorleistung reduziert.
7		LSI	Lineare System Identifikation dient dazu, lineares Verhalten der Systeme zu identifizieren. Dieses Verhalten wird am genauesten durch einfache lineare Ansätze beschrieben. Die verbleibenden nicht-linearen Anteile werden dann durch die ANN Methodik abgebildet.
8	Konfiguration von ANN Trainingsalgorithmen	Topologie	Ein ANN kann statische und dynamische Systeme abbilden. Verschieden Kombinationen von ANN-Topologien und klassischen Lösungsmethoden müssen getestet werden
9		ANN Größe	For ein ausgewogenes Verhältnis zwischen Genauigkeit, Trainingszeit und notwendiger Rechnerleistung scheint ein ANN mit 1-2 verborgenen Schichten geeignete. Unterschiedliche ANN Größen und Schichtzahlen müssen einstellbar sein.
10		Calibrator	Für stabile, genaue und effiziente ANN Algorithmen müssen Eingangsgrößen innerhalb eines bestimmten Wertebereichs gehalten werden. Ein Kalibrator-schicht vor der Eingangsschicht erfüllt diesen Zweck und transformiert die Eingangswerte auf ein Intervall von -1 bis +1. Analog werden auch die Ausgangssignale des ANN behandelt.
11		Trainingsalgorithmen	Unterschiedliche Trainingsalgorithmen müssen auswählbar sein. Außerdem werden verschiedenen Parameter wie Momentum und Korrekturfaktoren eingestellt.
12	Training	Start Training	Wenn alle Trainingsparameter eingestellt sind, werden die Trainingsalgorithmen durch die Prozedur Start Training aufgerufen
13		Pause	Pause erlaubt den Trainings Prozess anzuhalten, den Zustand einzufrieren und wieder zu starten

14		Terminate	Terminate erlaubt manuell alle Prozesse zu beenden.
15	Connect and run	Text file	Im Offline-modus können die Eingangssignale für das ANN als Text-File eingegeben werden. Die Ausgabe der ANN Berechnung werden ebenfalls in ein Textfile geschrieben und können dann für die Analyse herangezogen werden.
16		Network	Dieser Online-Betriebsmodus arbeitet auf der Eingabeseite entweder mit einer Simulationsumgebung oder den Sensordaten der realen Anlage, führt automatisch periodische Trainings durch und gibt die Ausgangssignale zurück an die Simulationsumgebung oder Anlage.
17		Memory share	Wenn andere Simulationssoftware auf dem gleichen Rechner läuft kann die Software mit dieser über Shared Memory kommunizieren.

Wie in Abbildung 12 zu sehen ist, werden die ANN Module nicht einfach ANN genannt sondern System. Der Grund hierfür ist, dass diese Objekte nicht nur ANN-Strukturen enthalten sondern auch viele andere Module. Es soll an dieser Stelle erwähnt werden, dass die Abgrenzung der verschiedenen Module auf den verschiedenen Ebenen nicht so eindeutig ist, wie es Abbildung 13 suggeriert. Beispielsweise ändert der Trainer nicht direkt die Gewichte der Neuronen. Um die Änderung der Gewichte ΔW zu berechnen benötigt der Trainer die genauen Werte der aktuellen Gewichte. Diese Information ist im ANN Kern verfügbar, auf welche der Trainingsalgorithmus Zugriff haben muss. Wenn ein solcher Zugriff allerdings direkt von außen erfolgt, so ist das modulare Prinzip verletzt was erhebliche Nachteile in vielerlei Hinsicht mit sich bringen würde. Die Lösung




Abbildung 12: Hauptmodule von WinANN auf dem obersten Programmlevel




Abbildung 13: Struktur der Systeme der ANN Software mit Kalibrator, Trainer und ANN Kern

dieses Problems erfolgt durch die Bereitstellung von Funktionen innerhalb des ANN Kerns, welche ΔW errechnen, und vom Trainermodul aufgerufen werden. Dabei übergibt das aufrufende Trainermodul einige wenige Variablen als Eingabe und erhält den Wert ΔW als Antwort. Die Details sind im folgenden Abschnitt beschrieben.

5.1.3 WinANN-Software

Die im Projekt erarbeitete Software WinANN ist ein Werkzeug, welches Datenmuster aus vorliegenden Datensätzen erlernen kann. Es reduziert den Datenraum und Umfang zunächst mit Hilfe einer Hauptachsentransformation. Danach werden mit Hilfe der Linearen Systemidentifizierung zunächst lineare Zusammenhänge ermittelt. Im letzten Schritt wird Hilfe der Methode der neuronalen Netzwerke die nichtlinearen Abhängigkeiten ermittelt. Auf diese Weise entsteht ein dynamisches black-Box Modell, welches komplexe nichtlineare dynamische Abhängigkeiten verschiedener Variablen abbilden kann.




Abbildung 14: Excel-Datensatz zur Verarbeitung mit WinANN

Dieses Modell wird benutzt, um im vorliegenden Fall zum Beispiel die Raumtemperatur im Gebäude als Funktion der äußeren Einflüsse (Außentemperatur, Einstrahlung, Speicherladezustand, Heizkreisvorlauftemperatur usw.) zu erlernen und zu prognostizieren. Damit ist die Basis geschaffen, um diverse Regelungsaufgaben wie zum Beispiel eine automatische Ermittlung der Heizkurve, die Beladungsoptimierung des Speichers und den optimalen Betrieb der solarthermischen Anlage zu erfüllen.




Abbildung 15: Konfiguration des ANNSystem-Moduls

5.1.4 Funktionen der WinANN-software

Das ANNSystem-Modul beinhaltet die Funktionen Hauptachsenanalyse mit der Ermittlung von Eigenvektoren und Eigenwerten, die Lineare System Identifikation und nicht-lineare ANN-Analyse. Es kann sowohl statische als auch dynamische Systeme verarbeiten. Die Software bietet eine ganze Reihe von Parametereinstellungen, insbesondere für das Training des ANN-Netzes. Außerdem werden gängige statistische Kennwerte wie Minimum, Maximum, Erwartungswert und Varianz ermittelt. Im Folgenden sollen nun beispielhaft die Nutzung und die Ergebnisse der WinANN-software gezeigt werden.




Abbildung 17: Konfiguration der Netzwerktopologie

Abbildung 14 zeigt einen Datensatz aus einem Excel-File für ein dynamisches System mit 10 Variablen und zwei Ausgabegrößen, welche einen nicht-linearen Zusammenhang abbilden. Diese können von WinANN verarbeitet werden. Die Daten werden in Form eines Textfiles der Software zur Verfügung gestellt. Im nächsten Schritt ist anzugeben, ob die Daten ein dynamisches oder ein statisches System beschreiben. Darüber hinaus ist zu entscheiden, welche Datenanalysetools zum Einsatz kommen sollen (Abbildung 15). Danach kann die Hauptachsenanalyse durchgeführt werden. Im vorliegenden Beispiel zeigt sich, dass die Eigenwerte ab der 5. Spalte sehr gering werden (Abbildung 16). Die Dimension des Datenraums kann daher auf 4 reduziert werden. Die Datentransformation mit der gewählten Dimension erfolgt dann durch die ANN-Software. Im Ergebnis konnten im Beispiel die ursprünglich 10 Variablen des Datensatzes auf 4 neue Variablen reduziert werden, ohne wesentliche Information zu verlieren. Damit ist der Datensatz bei der anschließenden Weiterverarbeitung wesentlich einfacher zu handhaben.

Um die Topologie des ANN-Netzes zu konfigurieren, ist zu definieren, wie viele Schichten das




Abbildung 16: Ergebnis der Hauptachsenanalyse

ANN Netzwerk haben soll und aus wie vielen Knoten jede Schicht bestehen soll. Für den Trainingsalgorithmus sind einige Parameter wie Korrekturfaktor der Gewichte, Momentum, Mutation und Abbruchkriterien (maximale Iterationszyklen, maximaler Fehler) festzulegen. Außerdem kann zwischen Batch Training, sequentiellem Training und gemischtem Training gewählt werden.

Das Ergebnis des Trainings für oben genanntes Beispiel eines nichtlinearen dynamischen Systems ist in (Abbildung 19) dargestellt. Zu sehen sind die original Ausgabewerte y_{dyn1} und y_{dyn2} sowie die mit Hilfe des ANN-Netzes simulierte Ausgabewerte ANN_{y_1} und ANN_{y_2} . Die Übereinstimmung ist hervorragend, obwohl die Dimension des Datenraums von 10 auf 4 reduziert wurde (Abbildung 19).




Abbildung 18: Parametrisierung des Trainingsalgorithmus




Abbildung 19: Vergleich der ursprünglichen Ausgabewerte des nichtlinearen dynamischen Systems und der durch das ANN Netz simulierten Ausgabewerte

5.2 Das Regelungsprogramm

Das vollständige Regelungsprogramm „ANNSolar“ besteht aus zwei Teilen, die unabhängig voneinander ausgeführt werden können: Das Regelungsprogramm „ANNSolar Controller“ und das ANN-Trainingsprogramm „ANNSolar Trainer“ (s. Abbildung 20). Dabei nutzt „ANNSolar Controller“ ANN-Systeme für die Steuerung der hydraulischen Anlage. Die ANN sind in Form von Parametern und Gewichtsmatrizen gegeben. Im laufenden Betrieb speichert ANNSolar Controller sowohl gesendete als auch gemessene Signale. Dadurch werden neue Datensätze erzeugt, die von „ANNSolar Trainer“ genutzt werden können, um die vorhandenen ANN nachträglich zu trainieren und sie damit durch zusätzliche Daten zu optimieren und auf die aktuellen Gegebenheiten einzustellen. „ANNSolar Trainer“ basiert auf dem während des Projekts erstellten Programm „WinANN“ (Abschnitt 5.1.3).

5.2.1 Verzeichnis der Sensoren, Aktoren und Parameter der Regelung

An dieser Stelle sollen zunächst die Bezeichnungen von Sensoren, Aktoren und Parameter der Regelung aufgelistet werden um für die nachfolgenden Beschreibungen die Gesamtheit der verwendeten Symbole, Größen, Wertebereiche und Erklärungen an einem Ort auffindbar darzustellen.

Bezeichnung	Alias	PU-Signal-Bez.	Umrech.-faktor (keyfile)	Einheit	Wertebereich (ca.! aus Daten)	Beschreibung
Date				dd.mm.yy		
Time				hh:mm:ss		
1T01	T_{col}	P1E1	0.1	°C		Temperatur des Solarkreises am Kollektorvorlauf 1. Wird genutzt, um die Kollektor-Pumpe (Kollektor-Seite, 1DIGout1) zu steuern. T. wird direkt am Kollektorausgang 1 gemessen. Die Volumenströme durch die beiden Kollektorfelder werden manuell so abgeglichen, dass die beiden Felder die gleiche Vorlauftemperatur erreichen.
1T02	$T_{col,2}$	P1E2	0.1	°C		VL Temp des Solarkreises am Kollektor 2, analog zu 1T01
1T03	$T_{col,ret}$	P1E3	0.1	°C		RL-Temp. Solarkreis, Kollektorseite, vor Abgleichventil
1T04	T_f	P1E4	0.1	°C	variiert 20 bis 65	VL-Temp, Heizkreis, Heizungsseite, hinter 3-Wege-Mischventil
1T05	T_r	P1E5	0.1	°C	variiert 18,5 bis 22,5	Raumtemperatur
1T06	T_{amb}	P1E6	0.1	°C		Außentemperatur
1T07		P1E7	0.1	°C		VL-Temp. Solarkreis, Kollektorseite vor Wärmetauscher. Wird genutzt, um die speicherseitige Pumpe 1DIGout2 zuzuschalten
1T08	$T_{st,3}$	P1E8	0.1	°C		Speichertemperatur, Position 3 (1 ist unten)
1T09	$T_{st,6}$	P1E9	0.1	°C	flukt. 25 bis 65	Speichertemperatur, Pos. 6 (1 ist unten). konv. Kriterium, um den Brenner auszuschalten (nur bei ursprünglicher Regelung!)
1T10		P1E10	0.1	°C		RL-Temp. Warmwasserkreis, Trinkwasserseite vor Wärmetauscher
1T11		P1E11	0.1	°C		VL-Temp. Warmwasserkreis, Speicherseite vor Wärmetauscher
1T12	$T_{st,1}$	P1E12	0.1	°C		Speichertemp. Pos. 1 (ganz unten)
1T13	$T_{st,8}$	P1E13	0.1	°C		Speichertemp. Pos. 8 (ganz oben). Wasser von hier fließt in den Heizkreis
1T14	$T_{st,7}$	P1E14	0.1	°C		Speichertemp. Pos 7 (1 ist unten). Wasser von hier fließt in den Warmwasserkreis
1T15	$T_{ws}/$ $T_{st,2}$	P1E15	0.1	°C		Kaminofentemperatur, neu zugewiesen am 10.02.2017. Früher Speichertemp. Pos. 2
1A01		P1A1	0.5	%	0 oder 100	An/aus-Schalter 220 V Solarkreispumpe 1 und 2, Kollektorseite und Speicherseite

1A02		P1A2	0.5	%	0 oder 100	An/aus-Schalter Heizkreispumpe. Pumpe wird auf minimaler Drehzahl betrieben
1A03		P1A3	0.5	%	0 oder 100	Schließsignal des 3-Wege-Mischventil-Motors im Heizkreis. Wenn == 100: Motor dreht sich mit konst. Geschw. und schließt das Ventil (weniger warmes Wasser im Heizkreis)
1A04		P1A4	0.5	%	0 oder 100	Öffnungssignal des 3-Wege-Mischventil-Motors im Heizkreis. Wenn == 100: Motor dreht sich mit konst. Geschw. und öffnet das Ventil (mehr warmes Wasser im Heizkreis)
1A05		P1A5	0.5	%	0 oder 100	Kesselsperrung nach Zeitplan bzw. bei Solarertrag in konventioneller Regelung, hat Priorität über 1A11
1A06		P1A6	0.5	%	0 oder 100	Drehzahl Pumpe Kesselkreis wird zusammen mit 2A10 gesteuert: Drehzahl hat 3 mögl. Werte (0, 45, 100%). 2A10 liefert 45% und 1A09 100% bei jeweils 1 $T_{15} > T_{12} + 3K$ und Mindestanforderung $T_{15} > 50^{\circ}C$. Signal 1A06 gibt 0 oder 100 aus und schaltet damit zwischen 2A10 und 2A09 um. Umschaltkriterium von 2A09 auf 2A10 ist $1T_{14} > 46^{\circ}C$.
1A07		P1A7	0.5	%	0 oder 100	An/aus-Schalter Solarkreispumpe 2, Kollektorseite. 1DIGout2 wird über Relais . erst freigegeben, wenn $1T_{17} > 1T_{12} + 6K$. ausschalten bei $1T_{17} < 1T_{12} + 2K$
1A08		P1A8	0.5	%	kont. 0 bis 100	Drehzahl Warmwasserkreispumpe 1, Speicherseite
1A09		P1A9	0.5	%	0 oder 100	Drehzahl Warmwasserkreis Zirkulationspumpe
1A10		P1A10	0.5	%	0	Nutzung für Datensynchronisierung
1A11	S_b	P1A11	0.5	%	0 oder 100	An/aus-Schalter Pelletbrenner. Konventionell geregelt abhängig von $1T_{13}$ und $1T_{14}$
1A12		P1A12	0.5	%	0 oder 100	Steuerung Warmwasserkreis-3-Wege-Umschaltventil
1DIGout1		P1DO1	1.0	%	kont. 40 bis 100 oder 0	Drehzahl Solarkreispumpe 1, Kollektorseite. Geregelt durch PI-Regelung zwischen 40 und 100%

1DIGout2		P1DO2	1.0	%	kont. 20 bis 60 oder 0	Drehzahl Solarkreispumpe 2, Speicherseite. Geregelt linear zu 1DIGout1, zwischen 20 und 60 % direkt proportional zum Signal 1DIGout1
FWRDF		FWRDF	0.01	l/min		Frischwasserdurchfluss
FWRTEMP		FWRTEMP	0.1	°C		Frischwassertemperatur
WWsoll		WWSoll	1.00	°C	konst. 42 (konv.)	Warmwassersolltemperatur (konventionell konst. auf 42°C)
T_VL_soll		VLSoll1	0.1	°C	flukt. 0 bis 60	VL-Solltemp. Heizkreis. Die Solltemp. 1T04 wird auf diese Temp. geregelt
T_VL_soll_2		VLSoll2	0.1	°C	0	ungenutzt
2T03				°C		RL-Temp. Warmwasserkreis, Speicherseite, nach Wärmetauscher
2T04				°C		VL-Temp Solarkreis, Speicherseite, vor Speichereinlass
2T05				°C		RL-Temp. Solarkreis Speicherseite, nach Solarkreispumpe 2
2T06	$T_{st,5}$			°C		Speichertemp. Pos. 5 (1 ist unten)
2T07				°C		RL-Temp. Heizkreis, Heizungsseite
2T12	$T_{st,4}$			°C		Speichertemp. Pos. 4 (1 ist unten)
2T15				°C		Kessel(Vorlauf-)temperatur, das thermostatisch gesteuerte Mischventil im Kesselkreis wird automatisch so kontrolliert, dass die Kessel-Rücklauftemperatur einen festen Wert einnimmt (Rücklaufanhebung zur Vermeidung von Kondensation)
2A10				%		siehe 1A06




Abbildung 20: Struktur des Programms „ANNSolar“




Abbildung 21: Input-Output-Schnittstelle

PC = Rechner, CM = Koppelmodul, PU = Power Unit, CU = Control Unit

Das Regelungsprogramm „ANNSolar Controller“ wurde in der Programmiersprache C++ geschrieben. Es beinhaltet ANN-Regelungsalgorithmen und konventionelle Regelungsalgorithmen. Das Programm ist logisch in mehrere Module gegliedert (s. Abbildung 20). Es erhält die Messdaten der hydraulischen Anlage und regelt die Vorlauftemperatur des Heizkreises (T_f) und den Betriebszustand des Pelletbrenners (S_b) nach den nachfolgend beschriebenen Algorithmen. Der Motor des Vorlaufmischventils wird entsprechend angesteuert. Die Steuerung der übrigen Bauteile wird der konventionellen Regelung überlassen.

5.2.2 Input-Output Schnittstelle und Kommunikation (Communication Module)

Der lokale Rechner (PC), auf dem das ANN-Programm läuft, kommuniziert mit einem am Fraunhofer ISE vorhandenen Server, um Sensor- und Aktorendaten mitzuschreiben, Wetterprognosedaten abzurufen und Softwareaktualisierungen durchzuführen. Er ist an das Hardware-Koppelmodul (CM für engl. Coupling module) angeschlossen, welches die Kommunikation zwischen der Power Unit (PU) des Reglers und dem PC herstellt (s. Abbildung 21). Die Power Unit bildet im Wesentlichen die Schnittstelle zwischen Sensoren und Aktoren und der Regelungsintelligenz. Die Ausgänge und Eingänge der PU sind mit den Komponenten der hydraulischen Anlage verbunden und können Signale senden und empfangen. Die PU ist außerdem noch mit der ursprünglichen Referenz-Kontrolleinheit (CU für engl. Control Unit) verbunden. Auf dieser CU laufen weiterhin die ursprünglich implementierten, bewährten Regelungsalgorithmen. Die CU verarbeitet gemäß der

implementierten Regelungslogik die gemessenen Sensorwerte und sendet Signale für die Ansteuerung der Ausgänge an die Power Unit (PU). Parallel hierzu läuft auf dem lokalen Rechner (PC) der ANN-Regelungsalgorithmus, welcher die gleichen Sensordaten zur Verfügung hat und ebenfalls Signale für die Ansteuerung der Ausgänge generiert. Es stehen somit zwei alternative Steuersignale für die Ausgänge bereit. Das Regelungskonzept der Testanlage erlaubt nun zu jedem Kommunikationsschritt für jeden einzelnen Ausgang separat zu entscheiden, welches der beiden Signale für die Regelung der Anlage genutzt werden soll.

Um überprüfen zu können, ob die PU schlussendlich auch die gewünschten Werte an die hydraulische Anlage weitergibt, wird zusätzlich ein Messsystem verwendet, das die Spannungssignale am Ausgang der Power Unit (PU) abgreift und mit den gewünschten Sollwerten vergleicht. Damit kann die Regelung überwacht und unerwartetes Verhalten überprüft werden.

Die ursprüngliche CU speichert ebenfalls Messdaten und gesendete Daten in minütlichen Zeitintervallen. Diese Messdaten können jedoch nur manuell von der SD-Karte abgerufen werden. Zur besseren Zugänglichkeit und um einen zeitnahen Vergleich der Steuerungen ermöglichen zu können, wurde geprüft, ob es eine Möglichkeit gibt, die Logdaten mit Hilfe einer virtuellen SD-Karte direkt auf den ANN-Rechner zu übertragen. Bisher konnte hierfür noch keine Lösung gefunden werden.

5.2.3 Das Sicherheitsmodul (Safety check module)

Die Messdaten der Sensoren der hydraulischen Anlage werden vom CM gelesen und via Storage module gespeichert. Die Sensordaten werden an das Sicherheitsmodul weitergegeben. Hier wird auf grundlegende Sicherheitsaspekte geprüft:

- Die Temperatur im Speicher darf eine maximale Grenze nicht überschreiten ($< 85^{\circ} \text{C}$)
- die gemessene Vorlauftemperatur des Heizkreises darf eine Maximaltemperatur nicht überschreiten ($< 65^{\circ} \text{C}$)
- der Solarkollektorkreislauf (Solarkreispumpe) darf nicht unter Stagnationsbedingungen betrieben werden (Kollektortemperatur $< 125^{\circ} \text{C}$)

Sind die Sicherheitsanforderungen nicht erfüllt, werden keine Signale (bzw. off-Signale) an das CM gesendet, wodurch die Signale der ursprünglichen CU erhalten bleiben. Die Kontrolle wird also an die ursprüngliche Referenzregelung zurückgegeben, die kritische Fälle in jedem Fall abdeckt.

Tabelle 2: Parameter des Ausgabemoduls

parameter set	PU/CU measured sensors, Ziel-Raumtemperatur (T_r_tg) (Zeitplan, siehe Tabelle unten), Ziel-Minimum-Trinkwassertemperatur T_dw_tg (Zeitplan, siehe Tabelle unten), Temperaturüberhöhung Trinkwasser-Speichertemperatur (DT_dw_tg = 3°C), Temperaturüberhöhung Vorlauf-Speichertemperatur (DT_st_hc = 3°C), ANN system Parameter, Wettervorhersagedaten, gespeicherte Mess-und Sendedaten der letzten Zeitschritte		
Inputs		Outputs	
I_ANN_1	Zeit und Datum, Außentemperaturprognose (T_amb_fc), Prognose solare Einstrahlung (GNI_fc), Prognose Wolkenbedeckung (CC_fc), Kaminofen ("wood stove")-Temperatur (T_ws), Momentane Raumtemperatur (T_r), T_r_tg (Zeitplan)	O_ANN_1	
I_1	Momentane Vorlauftemperatur (T_f), T_f des letzten Zeitschritts, T_f_tg from O_ANN_1	O_1	1A03, 1A04
I_ANN_2	Zeit und Datum, Außentemperaturprognose (T_amb_fc), Prognose solare Einstrahlung (GNI_fc), Prognose Wolkenbedeckung (CC_fc), Kaminofen ("wood stove")-Temperatur (T_ws), T_r (Tabelle von O_ANN_1), T_f_tg (const. von ANN_1), geloggte Werte des Brennerzustands (S_b) aus dem letzten Zeitintervall, momentane Speichertemperaturen (T_st_i), T_dw_tg (Zeitplan)	S_b_ANN	(ein Wert: an/aus)
I_2	T_st_7 = 1T14, T_dw_tg (table), safety temperature interval DT_dw_tg, T_st_dw_tg = T_dw_tg + DT_dw_tg, current boiler state (S_b = 1A11), boiler run time (t_b_run), minimum boiler run time (t_b_min = 15 min)	S_b_dw	(ein Wert: an/aus)
S_b_ANN and S_b_dw		O_2	1A11: Brenner an/aus

5.2.4 Das Ausgabemodul (Output processing module)

Das Ausgabemodul (Abbildung 22) erhält Messwerte und Parameter (Tabelle 2, Tabelle 3) und gibt im Wesentlichen zwei Steuerungssignale aus:

1. Die Ansteuerung des Mischventil-Motors:
 - a. 1A03 = 1: Motor schließt das Ventil, Motor dreht mit konstanter Geschwindigkeit
 - b. 1A04 = 1: Motor öffnet das Ventil, Motor dreht mit konstanter Geschwindigkeit

2. Die Ansteuerung des Hauptschalters des Pelletbrenners (das Signal wird mit $S_b := 1A11$ abgekürzt.)
 - a. $1A11 = 1$: Brenner an
 - b. $1A11 = 0$: Brenner aus

Die Steuerungssignale werden durch weitere Algorithmen bestimmt:

ANN_1 berechnet im Zyklus $t_{f,cycle}$ die optimale Vorlauf Solltemperatur ($T_{f,tg}$) für einen vorgegebenen Verlauf der Sollraumtemperatur ($T_{r,tg}(t_n)$) für die nächsten N Zeitschritte (siehe 5.2.5). $T_{f,tg}$ wird an die Mischventilsteuerung (Heating circuit mix valve control module) weitergegeben, welches im Zyklus $t_{mix,cycle}$ die Drehrichtung und Drehzeit des Motors berechnet (siehe 5.2.6).

Sowohl $T_{f,tg}$ als auch die Raumtemperatur-Zeitreihe werden von ANN_1 an ANN_2 weitergegeben, welches im Zyklus $t_{b,cycle}$ berechnet, ob der Pelletbrenner angeschaltet werden (bzw. bleiben) soll oder ausgeschaltet werden (bzw. bleiben) soll (siehe 5.2.8). ANN_2 gibt den Wert $S_{b,ANN}$ weiter. Zusätzlich wird vom „Drinking water temperature module“ in kleinstmöglichen Zeitabständen überprüft, ob die Trinkwassertemperatur vom Warmwasserspeicher gewährleistet werden kann. Dazu soll die Temperatur $1T14 (= T_{st,7})$ im Speicher (vgl. Abbildung 11) stets über der Temperatur $T_{st,dw,tg} = T_{dw,tg} + DT_{dw,tg}$ liegen, wobei $T_{dw,tg}$ die vom Nutzer festgelegte Trinkwassertemperatur und $DT_{dw,tg}$ eine Temperaturüberhöhung für den Wärmeübertrager bezeichnen.

Tabelle 3: Beispiel und Format der Vorgabe von Raumtemperatur und Trinkwassertemperatur durch den Nutzer

T_r_tg		T_dw_tg	
Monday 00:00	17	Monday 00:00	10
Monday 05:30	21	Monday 05:30	42
Monday 22:30	17	Monday 22:30	10
		Monday 05:30	42
Tuesday	17	Monday 22:30	10
...			
		Tuesday 22:30	10
Sunday 00:00	17	...	
Sunday 05:30	21		
Sunday 22:30	17	Sunday 22:00	10

Kann die Trinkwassertemperatur nicht gewährleistet werden, wird $S_{b,dw} = 1$ weitergegeben und der Brenner in jedem Fall eingeschaltet. Es soll erwähnt werden, dass die Energieeinsparung durch die ANN Nutzung reduziert wird, wenn der Nutzer entscheidet, dass zu jeder Tag-und-Nachtzeit eine hohe Warmwassertemperatur zur Verfügung stehen soll.

Abschließend wird sichergestellt, dass der Brenner ab Anschaltung immer mindestens eine Zeit $t_{b,run}$ in Betrieb ist, bevor er wieder abgeschaltet wird. Daraus ergibt sich das endgültige Pelletbrenner-Signal S_b (= 1A11) soll.

5.2.5 Regelung der Vorlauf-Solltemperatur des Heizkreises (Modul ANN_1)

Mit der ANN-Regelung wird das Ziel verfolgt, mit der geringstmöglichen Vorlauftemperatur die Raumtemperatur auf Komfortniveau zu halten. Dieser Ansatz besitzt ein weitaus größeres Optimierungspotential als eine fest eingestellte Heizkurve: Bei der Heizkurve fließen nur die aktuelle Raum- und die Außentemperatur in die Berechnung der Vorlauftemperatur ein. Gebäudespezifische Randbedingungen wie Dämmeigenschaften oder lokale Einstrahlungsbedingungen können hier nur gering oder gar nicht berücksichtigt werden. Die Folge ist, dass eine Heizkurve mit entsprechend großem Temperaturpuffer gewählt werden muss. Damit werden höhere Vorlauftemperaturen als notwendig eingestellt, um die Erwärmung des Wohnbereichs auf Komforttemperatur in jedem Fall sicherzustellen.

Der Ansatz der ANN-Regelung dagegen greift auf alle Informationen zurück, die in der Vergangenheit über das gebäudespezifische Temperaturverhalten gesammelt wurden. In dieser großen Menge der gesammelten Daten ist der Zusammenhang zwischen Vorlauftemperatur und Raumtemperatur für ganz unterschiedliche Randbedingungen (zum Beispiel Jahreszeit, Wochentag, Uhrzeit, Außentemperatur, Sonneneinstrahlung) enthalten. Dieser Zusammenhang ist für jedes Gebäude einzigartig. Die Stärke eines ANN-Systems liegt darin, diesen individuellen Zusammenhang aus den lokalen Messdaten extrahiert zu können und damit Prognosen für das thermische Verhalten von Gebäude und Anlagentechnik möglich sind. Die Möglichkeit der Vorhersage der zukünftigen Raumtemperatur für unterschiedliche Vorlauftemperaturen wird in der derzeitigen Implementierung der Regelung dazu genutzt, die geeignete Vorlauftemperatur einzustellen. Das Vorgehen dabei ist wie folgt im Modul ANN_1 Abbildung 23 implementiert.

Das Ziel ist es, die Raumtemperatur stets innerhalb eines Komfortintervalls zu halten, das vom Nutzer in Form einer Zeit-Tabelle vorgegeben wird. Als Einflüsse auf die Raumtemperatur und ihre Änderung berücksichtigen wir das Datum („Day of the week“), die formatierte Tageszeit („Minute of the day“) sowie den Wochentag („Day of the week“). Zeit und Datum werden durch Anwendung von Sinus und Kosinus in zwei Variablen zerlegt, um stetiges Verhalten ohne Sprünge bei 24 Uhr und am 1. Januar zu erreichen.




Abbildung 22: Ausgabemodul der ANN-Regelung




Abbildung 23: Modul ANN_1: Heizkreis und Format der Zeitvariablen




Abbildung 24: Modul ANN_1: Algorithmus zur Berechnung der Vorlaufsollltemperatur ($T_{f,tg}$)

Außerdem werden die Umgebungstemperatur (T_{amb}), die direkte Erwärmung der Wohnräume durch die Sonne (passiver Solareintrag durch Normaleinstrahlung der Sonne „GNI“ und Bewölkung „Cloud cover“), die Temperatur des Kaminofens („Wood stove temperature“) und die aktuelle Vorlaufstempertur als Inputvariablen für das ANN genutzt (s. Abbildung 23.). Das ANN soll die Korrelationen zwischen der Outputvariable Raumtemperatur T_r und den Inputs erlernen und Vorhersagen für die Raumtemperatur bei gegebenen Inputs machen. Dazu wurde der in Abbildung 24 dargestellte Algorithmus entwickelt, der nach dem in Abschnitt 4.2 beschriebenen Ansatz funktioniert.

In diesem Fall hat der Outputvektor \vec{y} nur eine Komponente $y := y_1 = T_r$. Für einen Zeitpunkt t_0 soll die optimale $T_{f,tg}$ bestimmt werden. Die Schrittweite t_s und die Anzahl N der Zeitschritte ($t_n = t_0 + n t_s$) werden zunächst auf $t_s = 15$ min und $N = 12$ gesetzt, können jedoch nach Bedarf angepasst werden. Aus den gesetzten Inputs $\vec{x}[n]$ ($n = 1, \dots, N$) und dem gemessenen Startwert $y[0]$ wird die Zeitreihe der Raumtemperatur $R(T_r)$ für die nächsten N Zeitschritte berechnet und mit der Komforttemperaturtabelle $T_{r,tg}$ verglichen, die vom Nutzer je nach Uhrzeit eingestellt werden kann (siehe Tabelle 3).

Für die benötigten, in der Zukunft liegenden Inputs müssen Vorhersagen gemacht werden. Für Zeit und Datum stellt dies kein Problem dar. Für die Umgebungstemperatur, den Solareintrag und die Bewölkung werden Wettervorhersagedaten aus dem Internet verwendet. Die Kaminofentemperatur wird für die die Zeit $t_{prog} = N \cdot t_s$ ab t_0 als konstant angenommen und auf die zuletzt gemessene Temperatur gesetzt. D.h., ist der Ofen zum Zeitpunkt der Berechnung an, wird angenommen, dass er für ca. 3 weitere Stunden brennt. Ist er aus, wird angenommen, dass er in den nächsten 3 Stunden nicht gestartet wird. Diese Berechnung wird alle $t_{f,cycle} = 15$ min wiederholt.

Für einen Startwert der Vorlauftemperatur von zunächst 20 °C werden für die nächsten drei Stunden mit dem ANN-System die zukünftigen Raumtemperaturen in 15-Minutenintervallen berechnet. Anschließend wird der gewichtete Mittelwert f der Abweichungen der Prognosen $T_r(t_n)$ vom Sollwert $T_{r,tg}(t_n)$ ermittelt:

$$f(T_{f,tg}) = \frac{\sum_{n=1}^N k_n (T_r(t_n) - T_{r,tg}(t_n))}{\sum_{n=1}^N k_n} \quad (5.1)$$




Abbildung 25: Prinzipieller Verlauf der Fehlerfunktion f mit der Vorlaufsolltemperatur $T_{f,tg}$

Die Vorlauftemperatur des Heizkreises $T_{f,tg}$ ist direkt und unmittelbar regelbar. Daher wird ein konstanter Wert $T_{f,tg}$ für die Zeit t_{prog} ab t_0 angenommen. Durch die Festlegung der Inputs ist jedes $y[n]$ eine alleinige Funktion der gewählten $T_{f,tg}$.

Die Fehlerfunktion (5.1) besitzt Gewichtskoeffizienten $k_n > 0$. Die Gewichtung der N Zeitschritte mit den Gewichtungsfaktoren k_n ist für die späteren Zeitschritte geringer und bewirkt, dass Abweichungen in der nahen Zukunft eine größere Relevanz besitzen. Ist der berechnete f -Wert größer als 0, dann wird die Vorlauftemperatur von 20 °C definiert. Wenn der f -Wert kleiner als 0 ist, dann wird die Vorlauftemperatur so lange erhöht, bis der Wert positiv wird. Die maximale Vorlauftemperatur, die im vorliegenden Fall dabei erreicht werden kann, ist 61°C.

Hinter diesem Ansatz steckt der Gedanke, dass der optimale Temperaturanstieg zur Erreichung der Zieltemperatur im Gebäude abhängig von Heizungstechnologie, Dämmstandard und thermischer Kapazität ist. Ein zu schneller Anstieg erfordert möglicherweise ungünstig hohe Vorlauftemperaturen, ein zu langsamer Anstieg unter Umständen zu lange Heizzeiten. Mit der oben beschriebenen Fehlerfunktion kann über die Definition der Gewichtskoeffizienten k_n und der Länge und Anzahl der Zeitschritte t_n der gewünschte Temperaturgradient für Aufheizung und Abkühlung insbesondere vor und nach einer Nachtabsenkung definiert werden.




Abbildung 26: f-Wert des Regelungsalgorithmus zu acht verschiedenen Zeitpunkten im Januar 2018. Der f-Wert ist ein gewichteter Mittelwert der Abweichung von Prognosewerten und Sollwerten der Raumtemperatur über die jeweils folgenden drei Stunden. Es wird immer die Vorlauftemperatur eingestellt, bei der der f-Wert das erste Mal einen positiven Wert annimmt.

$T_{f,min}$ ist eine festgelegte Mindesttemperatur im Vorlauf von 20 °C. Würde mit einer Vorlauftemperatur von $T_{f,min} = 20$ °C eine höhere Raumtemperatur als die gewünschte erreicht ($f(T_{f,min}) > 0$), wird der Zulauf des warmen Wassers in den Heizkreis geschlossen. Ist $f(T_{f,min}) \leq 0$, wird $T_{f,tg}$ in Schritten von $D = 1$ °C erhöht, bis der erste Wechsel von $f < 0$ nach $f > 0$ erfolgt oder die zulässige Maximaltemperatur im Vorlauf $T_{hc,lim}$ abzüglich einer Sicherheit $DT_{hc,safe}$ erreicht ist. Der so berechnete Wert der Vorlaufsolltemperatur wird an die Steuerung des Heizkreismischers übergeben. Das Verfahren wird alle $t_{f,cycle} = 15$ min wiederholt, wodurch eine laufende Anpassung der Vorlaufsolltemperatur erreicht wird. Die Analyse des Verhaltens der Regelung im realen Gebäude zeigt, einen trendmäßig ansteigender Verlauf der Fehlerfunktion mit der Vorlaufsolltemperatur ähnlich wie sie in Abbildung 25 prinzipiell dargestellt ist.

Abbildung 26 zeigt den tatsächlichen Verlauf des f-Wertes im realen Gebäude an einigen Tagen im Januar 2018. Dargestellt ist jeweils der Verlauf der Vorlauf temperaturbestimmung an verschiedenen Tagen und zu verschiedenen Uhrzeiten.

5.2.6 Schaltung der Heizkreispumpe

Die Heizkreispumpe wird von der ANN-Regelung eingeschaltet, sobald die ermittelte Vorlauf solltemperatur des Heizkreises größer als 20°C ist.

5.2.7 Ansteuerung des Mischventils (PD bzw. ID Regler)

Im Falle des Mischventils kann definiert werden, ob der Motor das Ventil öffnen oder schließen soll (Drehrichtung) und wie lange er dabei jeweils laufen soll (Drehzeit). Die Öffnungsgeschwindigkeit ist nicht beeinflussbar und der momentane Öffnungszustand des Ventils ist nicht verfügbar. Für die Drehzeit- und Richtung wird ein konventioneller PD-Regler verwendet (siehe Abbildung 27). Für die Regelung der Vorlauf temperatur nach der Vorlauf solltemperatur (gegeben durch ANN_1) ergibt sich dadurch ein Verhalten ähnlich eines ID-Reglers.

Der in Abbildung 27 dargestellte Algorithmus bestimmt die Zeit $|x|$, für die der Motor entweder in Öffnungs- oder Schließrichtung dreht. Dementsprechend wird entweder $1A03 = 1$ (Schließen) oder $1A04 = 1$ (Öffnen) für $|x|$ Sekunden gesendet. Danach werden beide Signale ($1A03/4$) auf 0 gesetzt. Um den Motor nicht zu beschädigen, darf niemals gleichzeitig $1A03 = 1$ und $1A04 = 1$ gesendet werden. Es werden folgende Bezeichnungen verwendet:

- $t_{mix,cycle}$: Zykluszeit, die Berechnung wird in diesem Zeitabstand wiederholt (30 Sek.)
- $t_{com,min}$: Minimale Kommunikationszeit zwischen zwei an die PU gesendeten Signalen (und auch zwischen zwei empfangenen Signalen) (= 1 Sek.)
- x_{min} : Minimale Drehzeit (in unserem Fall entspricht dies genau $t_{com,min} = 1$ s)
- x_{max} : Maximale Drehzeit (= $0.5 * t_{mix,cycle}$)
- x_{close} : Zeit zur vollständigen Schließung des Ventils (=130 Sek.)
- c_{dec} : Entscheidungs-Faktor („decision factor“) (= 0,5)

- x_{sign} : Vorzeichen von x ($x_{sign} = 1$ für positives Vorzeichen, $x_{sign} = 0$ für negatives Vorzeichen)
- t_0 : Momentaner Zeitpunkt
- $T_{f,min}$: Minimale Regelungstemperatur (= 20 °C), darunter findet keine Regelung des Heizkreises statt.
- B_{closed} : Anzeige, ob das Ventil vollständig geschlossen wurde (=1) oder noch offen ist (=0)
- C_{close} : Schließzeit-Zähler. Startet, wenn angefangen wird das Ventil zu schließen. Wenn ab diesem Zeitpunkt nur noch geschlossen wird, kann damit bestimmt werden, ob das Ventil vollständig geschlossen ist, wenn die Zeit x_{close} erreicht wurde

Aus der momentanen Vorlauftemperatur $T_f(t_0)$, der Vorlauftemperatur zur Zeit der letzten Regelung $T_f(t_0 - t_{mix,cycle})$ und der Vorlauf Solltemperatur von ANN_1, wird mit $\Delta T_f = T_f(t_0) - T_f(t_0 - t_{mix,cycle})$ die vorzeichenbehaftete Schließzeit x durch die Funktion f_m

$$x = f_m(T_f, T_{f,tg}, \Delta T_f) = k_I \cdot [T_{f,tg}(t_0) - T_f(t_0)] - k_D \cdot \frac{\Delta T_f}{t_{mix,cycle}} \quad (5.2)$$

berechnet. k_I und k_D sind optimierbare Regelungsparameter.

Falls $x < 0$, wird geschlossen. Falls $x > 0$, wird geöffnet. Der Motor wird jedoch nur betrieben, wenn die Mindestdrehzeit erfüllt ist, was durch $|x| > (x_{min} \cdot c_{dec})$ definiert ist. Auf Grund der minimalen Kommunikationszeit, wird somit entschieden, entweder für eine Sekunde zu drehen, oder überhaupt nicht zu drehen. Dies ist notwendig, um eine ständige Bewegung des Motors zu vermeiden und damit die Lebensdauer der Komponente zu erhöhen. Falls $T_{f,tg}$ unterhalb der minimalen Regelungstemperatur liegt, wird begonnen, das Ventil vollständig zu schließen und der Schließzähler wird in Gang gesetzt. Ist sichergestellt, dass das Ventil vollständig geschlossen ist, muss der Motor bei weiteren Werten $x < 0$ nicht weiter betrieben werden.




Abbildung 27: Ansteuerung des Mischventil-Motors

5.2.8 Regelung des Pelletbrenner-Signals (an/aus) (Modul ANN_2)

Bei einer konventionellen Regelung wird der Brenner des Heizkessels hinzugeschaltet (Signal S_b), wenn bestimmte Kriterien für die Temperaturen innerhalb des Warmwasserspeichers erfüllt sind. Dieser Ansatz führt jedoch dazu, dass die Nachheizung in einigen Fällen unnötigerweise eingeschaltet wird. Dies ist zum Beispiel dann der Fall, wenn die Sonne bald nach Einschalten des Brenners zu scheinen beginnt und ausreichend Wärme in den Speicher einbringen würde, oder wenn die Nachtabsenkung bald einsetzt und die vorhandene Wärme im Speicher noch ausgereicht hätte, um die Raumtemperatur im Komfortintervall zu halten. Der Einsatz von ANN soll dieses unnötige Einschalten des Brenners verhindern.

Abbildung 28 zeigt unter anderem die Temperaturmessfühler im Speicher. 1T13 ($= T_{st,8}$) bestimmt die Zulauftemperatur in den Heizkreis und ist für diesen Teil der Regelung die entscheidende Größe. Ihr Wert sollte möglichst über $T_{st,hc,tg}$ liegen, wobei $T_{st,hc,tg}$ der momentanen Vorlauf Solltemperatur des Heizkreises plus Temperaturüberhöhung $DT_{st,hc}$ entspricht ($T_{st,hc,tg} = T_{f,tg} + DT_{st,hc}$).

Analog zum Heizkreis stellt sich die Frage, was die Temperaturen im Speicher beeinflusst. Wir berücksichtigen als Einflüsse

- Zeit, Datum und Wochentag wie für ANN_1
- die Umgebungstemperatur wie für ANN_1
- Einstrahlung und Bewölkung, diese Information bildet in Kombination mit Speichertemperaturen, Tageszeiten und Datum den Solarertrag ab.
- die von ANN_1 vorhergesagte Raumtemperatur und Vorlauf Solltemperatur
- die (im jeweiligen Prognosehorizont konstant angenommene) Kaminofentemperatur wie für ANN_1
- den Heizkesselbetriebszustand S_b (Brenner an/aus)
 - im aktuellen Zeitintervall: $S_{b,ave}$, z.B. $S_{b,ave}(t_0)$ gemittelt über $[t_{-1}; t_0]$
 - im vorangegangenen Zeitintervall: $S_{b,ave,bef}$, z.B. $S_{b,ave,bef}(t_0)$ gemittelt über $[t_{-2}; t_{-1}]$

Diese Einflüsse bilden die Inputvariablen des ANNs, wie in Abbildung 28 dargestellt. Das ANN_2 berechnet die Speichertemperaturen $T_{st,l}$ auf verschiedenen Niveaus des Speichers für die nächsten N_b Zeitschritte (die Bedeutung der Abkürzungen $T_{st,l}$ ist in Abbildung 28 gegeben). Nach der Beschreibung aus Abschnitt 4.2 gilt damit für den Outputvektor \vec{y} .

$$y_1 = T_{st,1}, \quad y_2 = T_{st,3}, \quad y_3 = T_{st,6}, \quad y_4 = T_{st,7}, \quad y_5 = T_{st,8}$$

Die entscheidende Speichertemperatur für die Versorgung des Heizkreises ist $T_{st,8}$, entsprechend Output y_5 . Als Kriterium wird gewählt, dass $T_{st,8}$ am Ende des Prognosezeitraums eine Mindesttemperatur $T_{st,hc,tg}$ erfüllen soll (d.h. $y_5[N_b] > T_{st,hc,tg}$). Für einen Zeitpunkt t_0 soll entschieden werden, ob der Brenner ausgeschaltet wird (oder bleibt) oder eingeschaltet wird (oder bleibt).

Die $\vec{x}[n]$ liegen wiederum in der Zukunft. Vorhersagen für T_{amb} und Solareintrag werden wie zuvor über Internet-Wettervorhersagen realisiert. $T_{f,tg}$ wurde durch den ersten ANN Algorithmus bestimmt und wird als konstant angenommen. Die Raumtemperatur $T_r(t_n)$ wurde ebenfalls von ANN_1 berechnet. Die benötigten Startwerte der $T_{st,l}$ werden bei t_0 gemessen. Die Zeitintervalle $t_{s,b}$ können durchaus von denen der Heizkreissteuerung abweichen. Es wird zunächst $t_{s,b} = 15$ min. und $N_b = 4$ gewählt.




Abbildung 28: ANN_2: Pelletbrenner




Abbildung 29: ANN_2: Pelletbrenner, Algorithmus

Der Algorithmus zur Einstellung des Brennerzustands ist in Abbildung 29 dargestellt und wird jeweils nach der Zeitspanne $t_{b,cycle}$ wiederholt. Der Algorithmus unterscheidet sich von dem für die Vorlauf Solltemperatur des Heizkreises.

Das ANN_2 hat als einzigen aktiv steuerbaren Input die Zeitreihe des Brennerzustands $\{S_{b,ave}(t_n)\}$. Diese beschreibt die durchschnittlichen Brennerzustände in den Zeitintervallen $[t_{n-1}, t_n]$. Für die Prognose wird jeweils angenommen, dass die einzelnen Werte $S_{b,ave}(t_n)$ entweder 0 oder 1 sind (sie müssen jedoch nicht alle gleich sein). Der Input „Brennerzustand im vorangegangenen Zeitintervall“ $S_{b,ave,bef}(t_n)$, ergibt sich für alle t_n mit $n \geq 2$ aus $S_{b,ave,bef}(t_n) = S_{b,ave}(t_{n-1})$. Für $S_{b,ave,bef}(t_1)$ werden die gemittelten geloggtten Werte von S_b aus dem Zeitintervall $[t_0 - t_{s,b}; t_0]$ verwendet. Die Zusammenhänge sind in einem Beispiel für $N_b = 4$ in Abbildung 30 dargestellt. Alle anderen Inputvariablen sind entweder konstant oder ergeben sich aus Prognoseberechnungen.

Dem Algorithmus in Abbildung 29 folgend wird die Zeitreihe $\{S_{b,ave}(t_n)\}$ ausgehend von einer Initialkonfiguration systematisch variiert bis die Bedingung $y_5[N_b] > T_{st,hc,tg}$ erfüllt ist oder nicht mehr erfüllt werden kann, da alle definierten Sequenzen abgedeckt sind. Die Konfigurationen der Zeitreihe sind ebenfalls in Abbildung 29 beschrieben und in Abbildung 30 dargestellt. Der Algorithmus wird im Folgenden beschrieben.

Wir beginnen mit $S_b = 0$ für alle $t_n, n > 0$. Nun wird geprüft ob $y_5[N_b] > T_{st,hc,tg}$ für das Ende des Prognosezeitraums erfüllt ist ($t = t_0 + t_{prog} \Leftrightarrow n = N_b$). Falls dies erfüllt ist, wird der Brenner abgeschaltet (oder nicht angeschaltet).

Falls dies nicht erfüllt ist, wird im ANN $S_b[n] = 0$ für alle $n \leq (N_b - 1)$ und $S_b[N_b] = 1$ gesetzt (es wird also angenommen, dass der Brenner erst ganz am Ende eingeschaltet wird). Nun werden wiederum die $\vec{y}[n]$ berechnet und $y_5[N_b] > T_{st,hc,tg}$ für das Ende des Zeitraums geprüft. Falls dies erfüllt ist, wird der Brenner abgeschaltet.


Falls dies wiederum nicht erfüllt ist, wird im ANN $S_b[n] = 0$ für alle $n \leq (N_b - 2)$ und $S_b[n] = 1$ für $n \geq N_b - 1$ gesetzt (die Betriebsdauer des Brenners am Ende des Intervalls wird erhöht). Das Verfahren wird wiederholt, bis die Bedingung $y_5[N_b] > T_{st,hc,tg}$ erfüllt ist (dann wird abgeschaltet, also $S_{b,ANN} = 0$ gesetzt) oder bis der Brenner die ganze Zeit t_{prog} laufen muss, um die Bedingung zu erfüllen, beziehungsweise diese nicht erfüllbar ist, selbst wenn der Brenner die ganze Zeit läuft (dann wird der Brenner eingeschaltet, also $S_{b,ANN} = 1$ gesetzt).

Das Verfahren wird alle $t_{b,cycle} = 10$ min wiederholt, um kontinuierlich zu prüfen, ob eine Einschaltung sinnvoll ist oder nicht.

Die Länge des Prognosezeitraums muss festgelegt werden und hängt insbesondere von der thermischen Trägheit des Gebäudes ab. Höhere Trägheiten führen zu langsamerer Absenkung beziehungsweise Anhebung der aktuellen Raumtemperatur und erlauben daher längere Prognosezeiträume. Aus den Messwerten der Raumtemperatur über der Zeit und den Zuständen der Energieerzeuger (Solaranlage, konventionelle Nachheizung, passive Solarerträge, Kaminofen) könnte ein Kriterium bestimmt werden, welche die Länge des Prognosezeitraums definiert. Dies soll jedoch zunächst nicht weiterverfolgt werden.

Stattdessen ist zum jetzigen Zeitpunkt ein „Energiesparschalter“ geplant, mit dem der Nutzer manuell den Prognosezeitraum regulieren kann. Im Referenzfall starten wir bei $N = 4$ (also einer Stunde Prognose). Liegt N bei großen Werten, so ist es wahrscheinlicher, dass es zu einem gelegentlichen, kurzfristigem Absinken der Raumtemperatur unter den Sollwert kommen kann. Dadurch wird aber auch die benötigte Nachheizung reduziert, es wird also Energie eingespart. Der Nutzer kann entscheiden, wie wichtig ihm die Sicherheit in der Raumtemperatur ist und dementsprechend N (den Prognosezeitraum) größer oder kleiner einstellen.

Es scheint zunächst unnötig, alle sechs Speichertemperaturen als Output-Vektor des ANN berechnen zu lassen, da nur die oberste bei der Regelung überprüft wird und die anderen nicht weiter genutzt werden. Der Zustand aller Speichertemperaturen zum Zeitschritt n hat allerdings Auswirkung auf den Zustand der anderen Speichertemperaturen zum Zeitschritt $n + 1$. Durch das dynamische System wird dieses Verhalten berücksichtigt, indem man die anderen Schichttemperaturen als Output-Variablen berechnen lässt.



Calculate the storage tank temperatures ($T_{st,k}$) at t_n via ANN
 Def: $y_5[n] = T_{st,8}(t_n)$
 (Nomenclature: $T_{st,8} = IT13$)
 If condition $y_5[4] > T_{st,8,tg}$ **is** fulfilled for any try (# 1...4): switch boiler off or do not switch it on
 If condition $y_5[4] > T_{st,8,tg}$ **is not** fulfilled for try # 4: switch boiler on

Abbildung 30: ANN_2: Pelletbrenner, Berechnungsbeispiel für $N_b = 4$

5.2.9 Das Wetterprognose-Modul (Weather forecast module)

Für das ANN-Projekt wurde eine Vereinbarung mit dem meteorologischen Anbieter Meteoblue geschlossen (www.meteoblue.com). Meteoblue stellt uns historische und laufende Wettervorhersagedaten zur Verfügung. Diese können somit zum Training von ANN und zur Vorhersage durch ANN verwendet werden. Außerdem können Korrelationen zwischen den Vorhersagedaten für den Standort und den tatsächlich am Gebäude gemessenen Daten hergestellt und untersucht werden.

Im laufenden Betrieb werden stündliche Wetterprognosedaten für die nächsten sieben Tage in Form von Text-Dateien zweimal täglich über einen API-Zugang auf den ISE-Server geladen. Das Programm ANNSolar Controller hat Zugriff auf die jeweils aktuellste Textdatei und kann somit mit den Vorhersagedaten arbeiten. Da lediglich stündliche Vorhersagen vorliegen, werden diese linear interpoliert, wenn Input-Werte in kleineren Zeitintervallen benötigt werden (wie für ANN_1 und ANN_2).

5.3 Kombiniertes linearer/ nicht-linearer Prognoseansatz

Die im Projekt entwickelten Prognosefunktionen basieren auf einer Kombination eines linearen Ansatzes (LSI Linear System Identifier) mit einem nicht-linearen (ANN Artificial Neural Network). Dabei wird zunächst eine lineare Funktion generiert, welche den Zusammenhang zwischen Input- und Outputdaten bestmöglich darstellt. Die verbleibende Abweichung wird dann in einem zweiten Schritt durch einen nicht-linearen Ansatz beschrieben. Durch diese Vorgehensweise kann ein sehr robuster, genauer und schneller Prognosealgorithmus dargestellt werden.

5.3.1 Linearer Ansatz (LSI Linear System Identifier)

Ziel ist die Berechnung der Outputs $\vec{y}(t)$ aus Inputs $\vec{x}(t)$ zur Zeit t . Im dynamischen Fall werden die Outputs $\vec{y}(t)$ aus Inputs $\vec{x}(t)$ und den Outputs aus dem vorherigen Zeitschritt $\vec{y}(t - t_s)$ berechnet. Dieser Fall wird hier unter Nutzung der Methode der Linear System Identification (LSI) beschrieben.

Im Allgemeinen ist \vec{x} der Vektor der Inputvariablen mit Komponenten x_k , ($k = 1, \dots, K$) und \vec{y} der Vektor der Outputvariablen mit Komponenten y_m , ($m = 1, \dots, M$). Ein gegebenes ANN arbeitet auf einem Zeitraster mit diskreten Zeitpunkten $t_n = t_0 + n t_s$. Zu einem bestimmten Zeitpunkt t_n haben die Zustandsvektoren die Werte $\vec{x}[n] := \vec{x}(t_n)$ und $\vec{y}[n] := \vec{y}(t_n)$ mit Komponenten $x_k[n] := x_k(t_n)$ und $y_m[n] := y_m(t_n)$.

Für ein dynamisches System gilt somit

$$\vec{y}[n] = \vec{g}[\vec{x}[n], \vec{y}[n - 1]] \quad (5.3)$$

mit der gesuchten Funktion \vec{g} .

Bei der gemeinsamen Nutzung von ANN und LSI wird diese Funktion \vec{g} in einen linearen LSI-Anteil und einen nichtlinearen ANN-Teil aufgespalten. Die Linear System Identification (LSI) bestimmt im Analyse (oder Trainingsmodus) aus dem Trainingsdatensatz die linearen Zusammenhänge zwischen Input und Output-Daten und speichert diese Informationen in einer Matrix, die nachher im Auswertungsmodus (Berechnungsmodus) genutzt wird.

Mathematische Beschreibung:

Motiviert durch die Analyse linearer Systeme (vgl. [5]) wird beim linearen Ansatz angenommen, dass das dynamische Verhalten der Outputs durch folgenden Zusammenhang beschrieben werden kann:

$$\frac{d\vec{y}}{dt} = A \vec{y} + B \vec{x} \quad (5.4)$$

Hierbei sind A und B Matrizen mit konstanten Elementen. Prinzipiell sind letztendlich diese Matrizen während des Trainings zu ermitteln. Allerdings nimmt man einige Umformungen vor, die eine andere Darstellung ergeben. Zunächst wird die DGL durch den Ansatz

$$\frac{d\vec{y}}{dt} = \frac{\vec{y}(t) - \vec{y}(t - t_s)}{t_s} \quad (5.5)$$

diskretisiert. Bei der Approximation der Ableitung wird nicht wie üblich die Vorwärts-Differenz $\frac{\vec{y}(t+t_s) - \vec{y}(t)}{t_s}$ sondern die Rückwärts-Differenz verwendet. Dies hat jedoch keinen Einfluss auf die Genauigkeiten (den Fehler) bei der Approximation. In diskreter Form ergibt sich damit

$$\vec{y}[n + 1] = \dot{\vec{y}}[n + 1]t_s + \vec{y}[n], \quad (5.6)$$

wobei $\dot{\vec{y}}$ die Zeitableitung bezeichnet. Nach Einsetzen des Ansatzes (5.5) ergibt sich

$$\vec{y}[n + 1] = \tilde{A} \vec{y}[n + 1] + \tilde{B} \vec{x}[n + 1] + \vec{y}[n], \quad (5.7)$$

wobei $\tilde{A} = A \cdot t_s$ etc. Die optimalen Matrizen mit konstanten Koeffizienten \tilde{A}, \tilde{B} sind prinzipiell aus den Trainingsdaten zu ermitteln. Nach einigen Umformungen ergibt sich

$$\vec{y}[n+1] = \tilde{A} \vec{y}[n+1] + \tilde{B} \vec{x}[n+1] + \vec{y}[n], \quad (5.8)$$

$$\vec{y}[n+1] = C \vec{x}[n+1] + D \vec{y}[n], \quad (5.9)$$

wobei C und D wiederum Matrizen mit konstanten Elementen sind. Sind C und D einmal bestimmt, ist dies die Gleichung, mit der der lineare (LSI) Teil der Outputs im Auswertungsmodus aus den Inputs berechnet wird. Allerdings werden die Matrizen noch einmal in einer größeren Matrix zusammengefasst (s.u.).

Also sind C und D bei gegebenen Trainingsdaten zu bestimmen. Angenommen es liegen N Zeilen an Trainingsdaten vor, also N Vektoren $\vec{y}[n], n = 1 \dots N$. Die Vektoren werden in eine (transponierte) Trainingsdatenmatrix Y^T einsortiert:

$$Y^T = \begin{bmatrix} | & | & | & | & | \\ \vec{y}[1] & \vec{y}[2] & \vec{y}[3] & \dots & \vec{y}[N] \\ | & | & | & | & | \end{bmatrix} \quad (5.10)$$

Analog wird mit der Input-Trainingsdatenmatrix und der Matrix mit den Outputs vom jeweils vorigen Zeitschritt verfahren:

$$X^T = \begin{bmatrix} | & | & | & | & | \\ \vec{x}[1] & \vec{x}[2] & \vec{x}[3] & \dots & \vec{x}[N] \\ | & | & | & | & | \end{bmatrix} \quad (5.11)$$

$$Y_{bef}^T = \begin{bmatrix} | & | & | & | & | \\ \vec{y}[0] & \vec{y}[1] & \vec{y}[2] & \dots & \vec{y}[N-1] \\ | & | & | & | & | \end{bmatrix} \quad (5.12)$$

$\vec{y}[0]$ ist nicht vorhanden. Daher wird nur hier $\vec{y}[0] = \vec{y}[1]$ verwendet.

Mit (5.8) folgt

$$Y^T = C X^T + D Y_{bef}^T. \quad (5.13)$$

Fasst man C, D und X^T, Y_{bef}^T jeweils in einer Matrix zusammen, ergibt sich

$$Y^T = (C|D) \begin{pmatrix} X^T \\ Y_{bef}^T \end{pmatrix}, \quad (5.14)$$

und nach Transponieren

$$Y = (X|Y_{bef}) \begin{pmatrix} C^T \\ D^T \end{pmatrix} =: \tilde{X} Q,$$

mit

$$\tilde{X} := (X|Y_{bef}) \quad Q := \begin{pmatrix} C^T \\ D^T \end{pmatrix} \quad (5.15)$$

Zu bestimmen sind die $[(K + M) \times M]$ Elemente von Q . Es fällt nun auf, dass Y die Dimension $[N \times M]$ und X die Dimension $[N \times (K + M)]$ haben, die typischerweise viel größer sind als die von Q (N ist die Anzahl an Trainingsdaten-Zeilen). Die Informationsreduktion, die durch den linearen Ansatz zustande kommt, geschieht durch Multiplikation mit \tilde{X}^T :

$$\tilde{X}^T Y = (\tilde{X}^T \tilde{X}) Q \quad (5.16)$$

$(\tilde{X}^T \tilde{X})$ ist eine symmetrische, positiv semidefinite Matrix. Sind die (erweiterten) Inputs zudem zueinander linear unabhängig, (hat die Matrix also vollen Rang, bzw. eine Determinante ungleich 0), ist die Matrix $(\tilde{X}^T \tilde{X})$ positiv definit und damit invertierbar. Durch Invertieren wird letztendlich Q bestimmt:

$$Q = (\tilde{X}^T \tilde{X})^{-1} \tilde{X}^T Y \quad (5.17)$$

5.3.2 Nicht linearer Ansatz (ANN Artificial Neural Network)

Der lineare Ansatz wurde ausführlich in den vorherigen Abschnitten beschrieben.

5.3.3 Analyse von linearem und nicht-linearem Anteil der Prognosefunktionen

Im Folgenden soll nun analysiert werden, wie groß der lineare und der nicht-lineare Anteil an der Prognosefunktion im untersuchten Objekt ist. Hierfür wurden Trainingsdaten der Heizperiode 2016/2017 herangezogen.




Abbildung 31: Messwert, LSI-Anteil, ANN-Anteil und Summe der beiden für T8 (obere Speichertemperatur) an Tag 100 im Trainingsdatensatz der Heizperiode 16/17.

Beim Training eines Neuronalen Netzes mit der Trainingssoftware WinANN können der lineare Anteil (LSI-Anteil, Linear System Analysis) und der nicht-lineare Anteil (ANN) der Korrelationen zwischen Inputs und Outputs getrennt dargestellt werden.

5.3.3.1 Analyse des Netzes zur Vorhersage der Speichertemperaturen

Eine Untersuchung des Anteils von linearem und nichtlinearem Anteil ist immer nur empirisch in Bezug auf einen Inputdatensatz möglich. Bei der folgenden Analyse wurden die Trainingsdaten der Heizperiode 2016/2017 als Inputs verwendet. Pro Tag wurde eine Uhrzeit als Prognosebeginn festgelegt und dann ausgehend von diesem Startwert mit dem trainierten dynamischen Netz die Prognose für die kommenden Stunden erstellt.

Tabelle 4: Anteil von LSI und ANN am Output bei dem vollständig trainierten Speichertemperaturnetz.

Speichertemperatur	T1	T3	T6	T7	T8
Median LSI-Anteil	31,3 K	35,4 K	50,8 K	61,1 K	63,0 K
Median ANN-Anteil	0,12 K	0,19 K	0,17 K	0,22 K	0,16 K
Verhältnis LSI-Anteil / ANN-Anteil	258	189	291	271	385

Bei der Auswertung dieser Prognosen wurde dann der LSI-Teil und der ANN-Teil getrennt untersucht (siehe Abbildung 31). Für alle viertelstündlichen Werte nach Prognosebeginn um 9:00h Uhr wurde der LSI- und der ANN-Anteil berechnet ($15 \cdot 4 = 60$ Werte pro Tag für 273 Tage, also insgesamt pro Temperatur 16380 Werte). Tabelle 4 zeigt den Median dieser 16380 Werte. Das Verhältnis der Mediane von LSI-Anteil zu ANN-Anteil liegt bei allen fünf Speichertemperaturen weit über 100, der ANN-Anteil ist also in den meisten Fällen gegenüber dem linearen Anteil vernachlässigbar.

Tabelle 5: Anteil von LSI und ANN am Output bei dem kurz trainierten Speichertemperaturnetz.

Speichertemperatur	T1	T3	T6	T7	T8
Median LSI-Anteil	184 K	311 K	118 K	174 K	173 K
Median ANN-Anteil	25 K	9 K	7 K	9 K	4 K
Verhältnis LSI-Anteil / ANN-Anteil	7	35	16	18	44

Eine interessante Beobachtung ist, dass nach einem kurzen Training des zufällig initialisierten Netzes mit 200 Zyklen Batch der Anteil des ANN am Output stark erhöht ist (siehe Tabelle 5), und sich gleichzeitig die Kennzahl der oberen Speichertemperatur deutlich verschlechtert: Das 80 %-Quantil der obersten Temperatur T8 ist nach dem kurzen Training von 4,3 K auf 20,4 K gestiegen. Erst nach längerem Training wird ein Niveau erreicht, das niedriger ist als zu Beginn. Abbildung 32 zeigt den Verlauf von vier Kennzahlen in Abhängigkeit vom Trainingsfortschritt: Alle vier sind zu




Abbildung 32: Median und 90 %-Quantil für zwei und sechs Stunden Prognosehorizont von T8 im Trainingsverlauf. Es wurden fünf Trainingszyklen durchgeführt; ein Zyklus besteht aus 100 Epochen batch-Training.

Tabelle 6: Anteil von LSI und ANN am Output bei untrainiertem Speichertemperaturnetz.

Speichertemperatur	T1	T3	T6	T7	T8
Median LSI-Anteil	34,8 K	106,2 K	62,8 K	62,1 K	68,9 K
Median ANN-Anteil	0,65 K	2,93 K	0,35 K	1,52 K	0,34 K
Verhältnis LSI-Anteil / ANN-Anteil	54	36	178	41	202

Beginn niedrig, steigen dann stark an und erreichen dann erst ein Niveau unter dem des untrainierten Netzes.

Eine Analyse des Trainingsverlaufs zeigt, dass der ANN-Anteil zu Beginn des Trainings ebenfalls gering ist. Der vermutliche Grund dafür ist, dass das Netz zufällig initialisiert wurde und deswegen sich die Beiträge der einzelnen Synapsen statistisch gegenseitig aufheben. Das Gesamtsystem wird vom LSI-Anteil dominiert. In der ersten Phase des Trainings, wenn die optimalen Gewichte des ANN-Netzes gesucht werden, steigt zunächst der ANN-Anteil. Gleichzeitig nimmt die Vorhersagequalität des Netzes ab. Wenn lange genug trainiert wurde, geht der ANN-Anteil wieder fast auf 0 zurück (siehe Tabelle 4), und die Kennzahlen des – fast linearen – Systems sind leicht besser als zu




Abbildung 33: Messwert, LSI-Anteil, ANN-Anteil und Summe der beiden Anteile für das fertig trainierte Netz zur Vorhersage der Raumtemperatur. Gezeigt ist Tag 25 im Trainingsdatensatz der Heizperiode 16/17.

Tabelle 7: Anteil von LSI und ANN am Output des Raumtemperaturnetzes im Trainingsverlauf.

	Ohne Training	Nach 1. Training	Nach 2. Training	Nach 3. Training	Nach 4. Training
Median LSI-Anteil	32,2 K	18,6 K	20,5 K	20,4 K	20,5 K
Median ANN-Anteil	1,1 K	0,8 K	0,13 K	0,12 K	0,08 K
Verhältnis LSI-Anteil / ANN-Anteil	30	24	156	177	269

Beginn des Trainings. Tabelle 6 zeigt die Kennzahlen eines untrainierten Systems, nach zufälliger Initialisierung: Das System aus LSI + zufällig initialisiertem ANN besitzt ein 80 %-Quantil von 4,3 K (Abweichung zwischen Output und Messwert für die obere Speichertemperatur) für eine Prognose von T8 ab 9.00 Uhr mit einer Stunde Prognosehorizont. Für das lang trainierte System ist dieser Wert nur geringfügig besser, er beträgt 2,8 K.

Speichertemperatur-Netz: Analyse ohne ANN, nur mit LSI

Um die Hypothese zu überprüfen, dass die Prognose der Speichertemperaturen der Heizperiode 2016/2017 mit einem rein linearen System durchgeführt werden kann, wurde mit den gleichen Trainingsdaten in WinANN ein dynamisches System erstellt, das nur den LSI-Teil und keinen ANN besitzt. Das 80 % Quantil dieses Systems für T8 ist identisch mit dem der Kombination aus fertig trainiertem ANN und LSI (2,8 K). Damit ist die genannte Hypothese für den benutzten Trainingsdatensatz sowie die untersuchte Gebäude- und Anlagencharakteristik bestätigt. Ob die Hypothese auch für andere Randbedingungen gilt, ist zu untersuchen.

5.3.3.2 Analyse des Netzes zur Vorhersage der Raumtemperatur

Das System zur Prognose der Raumtemperatur zeigt ein ähnliches Verhalten wie das für die Speichertemperatur: Zu Beginn ist der Anteil des ANN gering, durch Training nimmt er erst (in diesem Fall nur leicht) zu und geht dann gegen Null. Tabelle 7 zeigt LSI- und ANN-Anteil im Trainingsverlauf. Nach Ende des Trainings ist der Anteil des LSI-Anteils 269 mal so hoch wie der ANN-Anteil, der Median des ANN-Anteils beträgt nur 0,08 K.

Abbildung 33 zeigt beispielhaft die Entwicklung von Messwert und Prognose der Raumtemperatur an einem Tag des Trainingszeitraums und die Anteile von LSI und ANN. Die Prognose besteht fast vollständig aus dem LSI-Anteil.

Raumtemperaturnetz: Analyse ohne ANN, nur mit LSI

Auch für die Vorhersage der Raumtemperatur wurde ein dynamisches System erstellt, das nur den LSI-Teil und keinen ANN besitzt, um zu testen, ob damit ähnliche Kennzahlen erreicht werden können. In diesem Fall wurde durch das reine LSI-System eine Verbesserung erreicht: Die 80%-Quantile dieses Systems der Abweichung zwischen Prognosen und Messwerten betragen 0,1 K, 0,4 K und 0,6 K für einen Prognosehorizont von 1, 3 und 6 Stunden. Zum Vergleich: Die Kombination aus trainiertem ANN und LSI lieferte Quantile von 0,5 K, 1,1 K und 1,5 K.

5.3.3.3 Ergebnisse der Analyse von LSI- und ANN-Anteil bei der Prognose

Die bisherigen Ergebnisse legen nahe, dass bei dem Messobjekt, welches für das Projekt ANNsolar herangezogen wurde, eine Prognose der thermischen Gebäude- und Anlagendynamik rein linear erfolgen kann. Ein nicht-linearer Ansatz (ANN) führt zu keiner Verbesserung, zum Teil sogar zu einer geringfügigen Verschlechterung. Daraus ergibt sich die Frage, ob diese Erkenntnis grundsätzlich gilt, oder dies nur den besonderen Eigenschaften dieses Gebäudes geschuldet ist.

Um diese Frage zu beantworten wurde ein Datensatz eines Gebäudes aus einem anderen Forschungsprojekt herangezogen, welcher ähnliche Zusammenhänge aus dem heizungstechnischen Bereich beschreibt. Der Datensatz beschreibt den Gesamtenergieverbrauch eines Gebäudes. Als Inputs stehen Wetter- und Belegungsdaten zur Verfügung. Diese Daten wurden mit dem Trainingsalgorithmus WinANN analysiert. Hierbei kam eine fünffache Kreuzvalidierung zum Einsatz: Der gesamte Datensatz wurde dazu in fünf Datensätze aufgeteilt, jeweils einer davon als Validierungsdatensatz gewählt und mit den restlichen Daten fünf Netze trainiert. Der Median des Verhältnisses von ANN- zu LSI-Anteil beträgt hier je nach Netz zwischen 0,24 und 0,38. In diesem Fall ist der nichtlineare Anteil im System also nicht vernachlässigbar.

Dieses Ergebnis legt den Schluss nahe, dass, je nach Charakteristik des Gebäudes, ein Prognosealgorithmus von Raumtemperatur und Speicherzustand sinnvoller Weise basierend auf einer Kombination von linearen und nicht-linearen Ansätzen weiterzuverfolgen ist.

Im Gebäude, welches im Rahmen des Projektes ANNsolar untersucht wurde, scheint es jedoch so zu sein, dass wegen der hohen thermischen Masse und der sehr guten thermischen Dämmung des Gebäudes die Prognose der Raumtemperatur allein durch einen linearen Ansatz erfolgen kann. Dies ist so zu interpretieren, dass die Veränderungen der Raumtemperaturen und der Speichertemperaturen so langsam erfolgt, dass ein rein linearer Ansatz dieses dynamische System sehr genau beschreiben kann.

Vermutlich ergibt sich bei der Betrachtung eines Gebäudes mit höherer thermischer Dynamik ein anderes Bild mit einem signifikanten nicht-linearen Anteil. Zumindest zeigt das in diesem Ab-

schnitt beschrieben Beispiel, dass es heizungstechnische Zusammenhänge gibt, die wesentlich nicht-lineare Anteile beinhalten.

Es bleibt der Nachweis zu führen, dass es Gebäude und Randbedingungen gibt, bei denen die thermische Dynamik des Gebäudes und des Speichers tatsächlich signifikante nicht-lineare Anteile enthält. Solange noch ungeklärt ist, ob bei der Prognose von Raumtemperatur und Speicherzustand in jedem Fall auf den nicht-linearen Anteil der Prognosefunktion verzichtet werden kann, ist sinnvoll einen Prognosealgorithmus beizubehalten, welcher sowohl lineare als auch nicht-lineare berücksichtigt.

5.4 Erstellung von Startmatrizen für den erstmaligen Einsatz der Regelung ohne das Vorhandensein von Trainingsdaten

Wenn die ANN-Regelung neu in einem Objekt installiert werden soll, tritt das Problem auf, dass anfangs noch keine Trainingsdaten zur Verfügung stehen. Folgende Lösung ist für den Zeitraum von einigen Wochen vorgesehen, in dem die ersten Trainingsdaten generiert werden.

Für die Speichertemperatur wird zunächst keine Prognose erstellt. Die Zuschaltung des Brenners erfolgt wie in einer konventionellen Heizungsregelung entsprechend den aktuell notwendigen Speichertemperaturen. In der Struktur der ANN-Regelung wird dies so umgesetzt, dass die Prognose für die zukünftige Speichertemperatur die aktuellen Werte fortschreibt.

Um eine Prognose der Raumtemperatur durchführen zu können, werden mit Hilfe einer virtuellen linearen Heizkurve Trainingsdaten generiert. Die Heizkurve beschreibt die notwendige Vorlauf-temperatur in Abhängigkeit von der Außentemperatur um eine gewünschte Raumtemperatur zu erreichen. Die Heizkurve beschreibt also einen statischen Zusammenhang zwischen Außentemperatur, Raumtemperatur und Vorlauf-temperatur.

Es konnte empirisch gezeigt werden, dass dieser Zusammenhang auch mit den gleichen Rechenalgorithmen dargestellt werden kann, wie sie zur Regelung mit selbstlernenden Algorithmen verwendet werden (ein dynamisches Netz mit LSI) (siehe Abschnitt 5.4.1). Der ANN Anteil wird dabei auf Null gesetzt, indem alle Koeffizienten der ANN Matrix auf Null gesetzt werden.

Wenn genügend Trainingsdaten vorhanden sind, werden die Netze für Speicher- und Raumtemperaturprognose trainiert, welche das individuelle Objekt beschreiben und darüber hinaus weitere Daten wie Sonneneinstrahlung, Außentemperaturprognose u.s.w. berücksichtigt.

Es ist in diesem Zusammenhang zu betonen, dass mit diesem Vorgehen zunächst nur ein statisches Netz generiert wird, welches nicht die thermische Dynamik des Gebäudes beschreibt. Der Prognosealgorithmus enthält zwar eine dynamische Rückkopplung, tatsächlich lernt das Netz aber, dass diese Rückkopplung zunächst keinen Einfluss auf die Raumtemperatur hat. Es lernt da-




Abbildung 34: Drei Heizkurven, die für die Erstellung der virtuellen Trainingsdaten genutzt wurden. Die Verwendung von je einer Heizkurve über bzw. unter dem Zielwert der Raumtemperatur von 21°C ermöglicht dem Netz eine Extrapolation über den Bereich der Trainingsdaten hinaus.

gegen einen zeitunabhängigen Zusammenhang zwischen Raumtemperatur, Vorlauftemperatur und Außentemperatur, so wie in der Heizkurve vorgegeben.

5.4.1 Empirische Überprüfung der Startmatrix

Für die Erstellung der Startmatrix wurde ein virtueller Trainingsdatensatz mit folgender Struktur erstellt. Gemäß einer linearen Heizkurve wurden geeignete Paare von Außentemperatur und Vorlauftemperatur für eine gewünschte Raumtemperatur von 21 °C definiert. Für eine Raumtemperatur von 20 °C und 22 °C werden zwei weitere Heizkurven definiert, welchen eine um 2,5 K höhere bzw. 2,5 K niedrigere Vorlauftemperatur zugrunde liegt (Abbildung 34). Der Wert 2,5 K pro Grad Raumtemperatur stammt aus einer Faustformel für den Heizungsbetrieb. Alle anderen Inputs werden mit Zufallszahlen belegt, damit das ANN lernt, dass diese Inputs nicht mit der Raumtemperatur korrelieren.

Folgende Heizkurve wurde beispielhaft für die Erstellung der Trainingsdaten für den Zusammenhang von Vorlauftemperatur (T_f) und Außentemperatur (T_{amb}) bei 21 °C Raumtemperatur benutzt,

$$T_f = -1,56 T_{amb} + 51^\circ\text{C} \quad (5.18)$$

wobei die maximale Vorlauftemperatur 70°C beträgt und die minimale 20°C. Damit beträgt die Vorlauftemperatur bei -12 °C Außentemperatur 70°C. Bei Außentemperatur 20 °C beträgt die Vorlauftemperatur 20 °C. Die Außentemperatur nimmt in den Trainingsdaten Werte zwischen -20 °C und 20 °C in Schritten von 0,1 °C an. Dies führt zu 401 Datenpunkten in den Trainingsdaten. Die dazugehörigen Vorlauftemperaturen wurden mit der Heizkurve berechnet und die Raumtemperatur auf 21°C gesetzt. Anschließend wurden für die gleichen Außentemperaturen mit jeweils 2,5 K höherer bzw. niedrigerer Vorlauftemperatur zu den Trainingsdaten hinzugefügt, wobei die Raumtemperatur dabei auf 22 °C bzw. 20 °C gesetzt wurde. Die anderen 8 Inputs wurden mit (zwischen -1 und 1) gleichverteilten Zufallszahlen besetzt. Das gesamte Trainingsfile enthält damit 1203 Zeilen zu je 11 Spalten und beschreibt für die genannte Spanne an Außentemperaturen die notwendigen Vorlauftemperaturen um 20 °C, 21 °C oder 22 °C Raumtemperatur zu erreichen.

Trainiert wurde das Netz mit 1000 Runden batch-Training und einem Schrittweitenfaktor von 0,1 (vergl. Abschnitt 3.4.1.1.1, S. 21). Die Analyse des trainierten Systems zeigt, dass der in der Heizkurve vorgegebene Zusammenhang vollständig von der linearen System Analyse abgebildet werden kann. Der LSI-Vektor hat in unserem Beispiel folgende Struktur und Inhalt.

$$\begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0,624 \\ 0 \\ 0 \\ 0 \\ 0,4 \\ 0 \end{pmatrix} \quad (5.19)$$

Die beiden Faktoren in den virtuellen Trainingsdaten (Verhältnis von 2,5 zwischen Änderung der Vorlauftemperatur und der Raumtemperatur, Verhältnis von 1,56 zwischen Außentemperaturänderung und Vorlauftemperaturänderung) sind durch ihre Kehrwerte im LSI-Vektor abgebildet. Durch diese Erkenntnis erhält man die Möglichkeit, auf das Training des Netzes zu verzichten und die Konfigurationsdatei des Netzes stattdessen direkt zu erstellen.

Für die Analyse des trainierten Netzes wurden alle Inputs außer Vorlauftemperatur und Außentemperatur auf 0 gesetzt. Der Startwert für die Raumtemperatur beträgt 20 °C. Die Ergebnisse zeigen, dass das Netz die korrekte Raumtemperatur prognostiziert, wenn die zur Außentemperatur passende Vorlauftemperatur eingestellt wird. Bei zu hoher bzw. zu niedriger Vorlauftemperatur wird die positive bzw. negative Abweichung korrekt abgebildet. Der lineare Zusammenhang wird über den gesamten Temperaturbereich auch oberhalb 22 °C und unterhalb von 20°C abge-

bildet. Der gewählte Ansatz ist also geeignet, um in den ersten Wochen nach Installation der Regelung den Betrieb der Heizungsanlage zu ermöglichen.

5.5 Erforderliche Rechnerleistung und Speicherkapazität der ANN Algorithmen

Begrenzte Rechnerleistung und RAM² ist häufig eine Herausforderung im Zusammenhang mit ANN. Grund für hohe Rechnerleistung sind normalerweise die Trainingsalgorithmen. Hohe RAM Kapazität ist notwendig, um auch während der Trainingsphase auf Daten Zugriff zu bekommen. ANNSolar adressiert insbesondere Regelungshardware mit beschränkter Rechnerleistung und Speicherkapazität. Es ist deshalb wichtig, im Entwicklungsprozess notwendige Anforderungen an die Hardware abzuschätzen, zu bewerten und gegebenenfalls die Methoden in dieser Hinsicht zu optimieren.

Dieser Abschnitt widmet sich den Anforderungen der ANN Algorithmen bezüglich Training und Regelungsbetrieb sowie denen von PCA und LSI Algorithmen.

Für eine Abschätzung sollen zunächst einige Randbedingungen geklärt werden:

Alle Reelle Zahlen sollen als Float Variablen gespeichert werden. Dies bedeutet, dass die Speicherung jeder Zahl 4 bytes benötigt. Dies gilt für die Software, die auf der lokalen Hardware läuft. In der PC Version der Software können auch 8 bit Zahlen verwendet werden. Dies kann helfen, Fehler im Zusammenhang mit Zahlenformaten einfacher zu finden.

Zweiter Punkt ist die Vereinbarung, dass alle ANN mehrere Eingangssignale verarbeiten können, jedoch nur ein Ausgangssignal generieren (multi-input und single-output (MISO)), um die Komplexität gering zu halten. Eine komplexere Regelungsanforderung (multi-input multi-output (MIMO)) mit mehreren Ausgangssignalen kann dann durch Kopplung mehrerer ANN erfüllt werden.

Die Dritte Annahme ist, dass Datenerfassung innerhalb des Systems alle 5 Minuten stattfindet. Damit entstehen etwa 100k Datensätze pro Jahr. Sollte die Speicherkapazität des Systems begrenzt sein, kann nach einem Jahr wieder begonnen werden, die ältesten Daten zu überschreiben. Die notwendige Speicherkapazität für ein Jahr Datensammlung beträgt demnach $m \cdot 100k \cdot 4$ bytes, wobei m die Anzahl der Eingangssignale des Systems beschreibt.

² Random Access Memory

5.5.1 Erforderlicher Speicherbedarf und notwendige Rechnerleistung für LSI

Die Lineare System Identifikation (LSI) ist eine Art curve fitting Methode, welche das beste lineare System ermittelt, welche das dynamische Verhalten eines physikalischen Systems beschreibt. Die verschiedenen Prozessschritte mit den jeweiligen Anforderungen werden nachfolgend beschrieben.

Ermittlung $X^T \cdot X$ und $X^T \cdot Y$: Wenn bei jeder Messwerterfassung der Vektor der Eingangssignale multipliziert und zur existierenden Matrix Q addiert wird, dann erfordert die Berechnung von $X^T \cdot X$ jedes Mal $m \cdot m$ Multiplikationen und Additionen. Da $X^T \cdot Y$ eine niedrigere Dimension hat, werden hier nur $m \cdot 1$ Rechenschritte benötigt. Die Gesamtzahl der Rechenschritte beträgt daher:

$$\text{operations} = m \cdot (m + 1) \cdot 100k \quad (5.20)$$

Eine Matrix der Größe $m \cdot m$, ein Vektor der Größe m welcher die Eingangssignale beinhaltet sowie ein weiterer Vektor der Größe m welcher Y beinhaltet müssen gespeichert werden.

Berechnung von $(X^T \cdot X)^{-1}$: Dies erfordert die Berechnung der Inversen einer $m \cdot m$ Matrix. Da diese Matrix nur Zahlenwerte und keine Parameter enthält ist hier ein Gauss-Jordan Verfahren die richtige Wahl. Diese Methode erfordert eine Anzahl von Rechenschritten gemäß (5.21).

$$\text{operations} = 2m \cdot m \cdot (m - 1) \quad (5.21)$$

Der erforderliche Speicherplatz ist $2 \cdot m \cdot m$.

Ermittlung der Koeffizienten des Systems mit $(X^T \cdot X)^{-1} \cdot X^T \cdot Y$: Dieses ist der letzte Schritt der LSI-Methode. Hierbei wird eine $m \cdot m$ Matrix mit einem $m \cdot 1$ Vektor multipliziert. Die Gesamtzahl der Rechenschritte summiert sich zu $m \cdot m$. Um die Berechnungen durchführen zu können, sind die genannte Matrix und der Vektor zu speichern. Der notwendige Speicherplatz beträgt daher $m \cdot m + 2m$.




Abbildung 35: Ein Netzwerk definiert durch m Eingabewerte und 1 verborgene Schicht mit n Neuronen

5.5.2 Erforderliche Rechnerleistung für ANN im Regelungsmodus

Es wurde bereits erwähnt, dass das neuronale Netzwerk in 2 unterschiedlichen Modi arbeitet. Der Regelungsmodus empfängt die Eingangssignale und generiert die für die Regelung der Anlage notwendigen Ausgangssignale. Der andere Modus ist der Trainingsmodus, welcher später behandelt wird.

Abhängig von der Anzahl von verborgenen Schichten sind unterschiedliche Rechnerleistungen und Speicherkapazitäten notwendig. Der folgende Abschnitt berechnet die notwendigen Ressourcen für eine (h-layer) bzw. zwei (2h-layer) verborgene Schichten während des Regelungsmodus.

5.5.2.1 Notwendige Ressourcen für ein Netz mit einer verborgenen Schicht (1 h-layer Netz)

Um die Ausgabewerte in Abhängigkeit der Inputs zu berechnen muss der Vektor V_0 mit der Matrix M_0 multipliziert werden (Abbildung 35). Dies erfordert $(m+1)*n$ Rechenschritte.

Danach muss der Ausgabewert jedes Neurons in der verborgenen Schicht mit der Funktion $\tanh()$ berechnet werden. Wenn $\tanh()$ in Form einer Wertetabelle gespeichert wird, ist die notwendige Rechenzeit zu vernachlässigen. Im zweiten Schritt muss der Ausgabewert jedes Neurons der verborgenen Schicht mit M_1 multipliziert werden, um den Ausgabewert zu berechnen. Dieser Schritt erfordert weitere $n+1$ Rechenschritte. Die Gesamtzahl der Rechenschritte ergibt sich damit zu:




Abbildung 36: Ein Netzwerk definiert durch m Eingabewerte und 2 verborgene Schichten mit jeweils n Neuronen

$$\text{operations} = (m+1) * n + (n+1) \quad (5.22)$$

Die Rechenschritte benötigen genügend Speicherkapazität, um den größten Eingabevektor und die eine Matrix, welche die Gewichte beinhaltet sowie einen Ausgabevektor abzuspeichern. Dies summiert sich zu

$$\text{memory} = \max(m+1, n+1) + (m+1) * n + n \quad (5.23)$$

5.5.2.2 Notwendige Ressourcen für ein Netz mit 2 verborgenen Schichten (2 h-layer Netz)

Wie Abbildung 36 zeigt, hat dieses Netz mehr Schichten, was mehr Prozessorleistung notwendig macht. Dabei ist eine weitere Vektor-Matrix-Multiplikation erforderlich. Die Zahl der Rechenschritte ist daher




Abbildung 37: Es existieren n Wege vom Ausgangsneuron zum gleichen Gewicht der ersten verborgenen Schicht.

$$operations = (m + 1) * n + (n + 1) * n + (n + 1) \tag{5.24}$$

Der notwendige Speicherplatz wird jedoch nicht anders als beim 1 h-layer Netz sein. Der Grund dafür ist, dass nach der Multiplikation jeder Schicht, das RAM wieder frei gegeben werden kann und für die Berechnung der folgenden Schicht wieder zur Verfügung steht.

5.5.3 Erforderliche Rechnerleistung für ANN im Trainingsmodus

Der Trainingsmodus erfordert mehr Prozessorleistung als der Regelungsmodus. In diesem Fall sind für jedes Neuron eine Reihe von Rechenschritten erforderlich. In diesem Abschnitt werden die notwendigen Ressourcen für einen Trainingsdurchlauf für ein 1 h-layer Netz und ein 2 h-layer Netz beschrieben.

5.5.3.1 Erforderliche Ressourcen für ein 1 h-layer Netz

Die Berechnungsverfahren im Trainingsfall, welche im vorhergehenden Bericht beschrieben wurden, zeigen dass jedes Neuron 3 Rechenschritte je Verbindung mit einem folgenden Neuron durchlaufen muss. Die Zahl der notwendigen Rechenschritte ergibt sich zu

$$operations = 6(m + 1) * n + 3(n + 1) \tag{5.25}$$

Das RAM muss den notwendigen Speicherplatz für alle Gewichte und deren Ableitungen zur Verfügung stellen. Die Größe ist:

$$memory = 2 * [(m + 1) * n + (n + 1)] \tag{5.26}$$



Abbildung 38: Testgebäude mit in der Fassade montierten Kollektoren

5.5.3.2 Erforderliche Ressourcen für ein 2 h-layer Netz

Das 1 h-layer und 2 h-layer Netz unterscheiden sich nur in der ersten Schicht. Die für das Training der Gewichtsmatrizen M_2 und M_1 des 2 h-layer Netzes notwendige Rechnerleistung ist identisch mit der Rechnerleistung für die Berechnung der Gewichtsmatrizen M_1 und M_0 des 1 h-layer Netzes. Die Gewichte von M_0 eines 2 h-layer Netz folgend allerdings einem anderen Weg. Um vom Ausgang zu ihnen zu gelangen müssen 3 Neuronen passiert werden. Also müssen 9 Rechenschritte je Gewicht durchgeführt werden. Außerdem existieren unterschiedliche Wege, um zum gleichen Gewicht zu gelangen. Wie Abbildung 37 zeigt gibt es jeweils n mögliche Wege. Entsprechend ist die Zahl der Rechenschritte für jeden Trainingsdurchlauf der Gewichte der ersten verborgenen Schicht $9 \cdot n$.

Die Gesamtzahl der Rechenschritte für einen Trainingsdurchlauf ist daher:

$$\text{operations} = 9(m+1)n * n + 6(n+1) * n + 3(n+1) \quad (5.27)$$

Die notwendige Speicherkapazität ist:

$$\text{memory} = (m+1)n + (n+1) * n + (n+1) \quad (5.28)$$




Abbildung 39: Vereinfachtes Hydraulikschema der Versuchsanlage

6 Bewertung der Funktionalität im realen Gebäude

6.1 Reales Testgebäude

6.1.1 Beschreibung der Testanlage

Dieses Kapitel beschreibt die solarthermische Kombianlage, welche für die Validierung der ANN Algorithmen herangezogen wird. Im Fokus stehen dabei die einzelnen Kreisläufe, welche mit der ANN Methodik geregelt werden sollen sowie die Regelalgorithmen, auf welchen die bisherige Regelung der Anlage basiert. Abbildung 39 zeigt ein vereinfachtes Schema der Anlagenhydraulik bestehend aus einem Heizkreis mit Mischventil, einem Trinkwarmwasserkreis mit Wärmeübertrager zur instantanen Warmwassererzeugung, einem Brennerkreis mit Pelletkessel und einem hydraulisch getrennt eingebundenen Solarkreis. Der Speicher ist zentrales Element zur hydraulischen und thermischen Entkopplung von Wärmequellen und Wärmesenken.

Abbildung 40 zeigt das detaillierte Hydraulikschema der Testanlage. Die Anlage besteht im Wesentlichen aus 4 Kreisläufen: a) Solarkreis, b) Kesselkreis, c) Trinkwarmwasserkreis und d) Heizkreis. Wesentliche Sicherheitskomponenten sind ebenfalls dargestellt, werden jedoch nicht weiter erläutert, da diese nicht relevant für die Projektergebnisse sind.

6.1.1.1.1 Der Solarkreis

Der Solarkreis besteht aus zwei Unterkreisläufen welche durch einen Wärmeübertrager getrennt sind. Der Wärmeübertrager überträgt die vom Kollektor generierte Wärme aus dem mit einer Wasser-Glykollmischung gefüllten Kollektorkreis zum Wasserkreis, welcher den Speicher thermisch belädt.

Das Kollektorfeld besteht aus zwei unterschiedlich großen Teilfeldern, mit 3 bzw. 4 Kollektoren. Beide Teilfelder haben separate Rücklaufleitungen und eine gemeinsame Vorlaufleitung. Über ein Drosselventil im Rücklauf sind beide Teilfelder hydraulisch abgeglichen. Beide Teilfelder sind nach Süden ausgerichtet und vertikal in der Fassade des Gebäudes integriert.

Das Signal 2A01 bzw. 2A02 schaltet die Pumpen ein bzw. aus. Das Signal 1DIGout1 bzw. 1DIGout2 steuert die Drehzahl der Pumpe.

6.1.1.1.2 Der Kesselkreis

Ein Pelletkessel liefert die zusätzlich notwendige thermische Energie für den Fall, dass die momentan verfügbare bzw. gespeicherte solarthermische Energie nicht ausreicht, um das Gebäude mit Wärme zu versorgen.

Die Kesselanforderung erfolgt durch Signal 1A11. Der Kessel verfügt über eine Temperaturregelung, welche die Kesselleistung zwischen 3 und 10 kW so regelt, dass die Kesselvorlauftemperatur einen fest eingestellten Wert erreicht.

Das Signal 2A10 steuert den Volumendurchfluss durch den Kessel. Hierbei wird zwischen zwei fest voreingestellten Pumpendrehzahlen geschaltet. Ziel ist, bei geringerem Wärmebedarf die Kesselleistung zu drosseln. Um Kondensation und damit Korrosion im Kessel zu vermeiden, sind Mindesttemperaturen im Kesselkreis einzuhalten.

6.1.1.1.3 Der Trinkwarmwasserkreis

Dieser Kreis versorgt das Gebäude mit warmem Trinkwasser. Zwei Pumpen und ein Wärmeübertrager sind die Hauptkomponenten dieses Kreises. 1A08 regelt die Drehzahl der speicherseitigen Pumpe in Abhängigkeit von Kaltwassertemperatur, Zapfvolumenstrom und Zieltemperatur. 1A09 schaltet die Zirkulationspumpe.

Um eine thermisch geschichtete Beladung und damit eine hohe Effizienz des Speichers zu erreichen, schaltet das Signal 1A12 ein 3-Wege-Ventil in Abhängigkeit von der Rücklauftemperatur.

Dieser Kreislauf wird im Rahmen des Projektes nicht mit einem ANN Algorithmus geregelt und daher im weiteren Verlauf nicht weiter detailliert.

6.1.1.1.4 Der Heizkreis

Hauptkomponenten dieses Kreises sind die Heizkreispumpe sowie ein Dreiwegeventil zur Regelung der Vorlauftemperatur des Heizkreises. Die Pumpe wird durch das Signal 1A02 ein- und ausgeschaltet. Die Pumpe besitzt eine interne Konstantdruckregelung. Diese wird allerdings nicht genutzt, da die Pumpe konstant bei Ihrer minimalen Drehzahl gefahren wird.




Abbildung 40: Hydraulik der Versuchsanlage

Die Position des 3-Wege-Mischventils wird so geregelt, dass eine in Abhängigkeit der Außentemperatur definierte Vorlauftemperatur eingehalten wird. Die Optimierung dieser Temperaturdefinition in Sinne einer Steigerung der Energieeffizienz ist eine wesentliche Aufgabe des Projektes.

6.1.1.2 Ursprüngliches Regelungskonzept der Testanlage

Im Folgenden werden die Regelungsalgorithmen des ursprünglichen Regelungskonzeptes der Testanlage beschrieben, welche für die ANN Regelung relevant sind. Die Testanlage läuft vor der Implementierung der ANN Regelung auf Basis dieser ursprünglichen Regelung und dient als Referenz für die Bewertung der ANN Regelung.

6.1.1.2.1 Regelung des Solarkreises

Der Solarkreis besteht aus dem Kollektorkreis und dem Speicherladekreis. Die Regelung des Kollektorkreises ist in Abbildung 41 dargestellt. Zu Beginn des Regelungsablaufes wird die Temperaturdifferenz zwischen Kollektor 1T01 und Speicher unten 1T12 ermittelt. Ist die Temperaturdifferenz größer als ein vorgegebener Wert ΔT_{on} , so wird die Startroutine begonnen und die Spannungsversorgung 1A01 der Pumpe eingeschaltet. Nächster Schritt ist die Sicherheitsüberprüfung, ob die Speichertemperaturen 1T13 und 1T14 unterhalb der maximal zulässigen Speichertemperatur T_{str_lim} liegen. Ist dies der Fall, wird über das PWM Signal 1DIGout1 die Pumpe für einen Zeitraum X zunächst mit maximaler Drehzahl in Gang gesetzt, um ggfs. notwendige erhöhte Anlaufdrehmomente sicher darzustellen. Nach dem Anlauf des Zeitraumes X wird die Drehzahl der Pumpe über einen PI Algorithmus so geregelt, dass eine konstante Temperaturdifferenz zwischen dem Kollektor 1T01 und dem Speicher unten T12 gehalten wird. Dabei kann die Drehzahl der Pumpe zwischen einem einstellbaren Min- und Maxwert variiert werden. Die möglichen Werte liegen zwischen 15% und 100%. In der Testanlage ist der Minwert auf 20% und der Maxwert auf 100% eingestellt.

Fällt die Temperaturdifferenz 1T01-1T12 unter einen einstellbaren Wert ΔT_{off} , so wird die Drehzahl der Pumpe über 1DIGout1 auf 0 gesetzt. Wird innerhalb eines Zeitraumes Y nicht wieder die Einschaltbedingung $1T01-1T12 > \Delta T_{on}$ erreicht, so schaltet auch die Spannungsversorgung 1A01 ab.

Die Regelung des Speicherladekreises des Solarkreises (Sekundärkreis)(Abbildung 42) läuft nach einer sehr ähnlichen Anweisung ab. Der wesentliche Unterschied besteht darin, dass die Temperaturdifferenz 1T07-1T12 ausgewertet wird und als Kriterium für die Drehzahlregelung der Pumpe des Speicherladekreises dient. Die Drehzahl der Speicherladepumpe (1DIGout2) wird proportional zur Drehzahl der Pumpe des Kollektorkreises gesteuert sobald $1T07-1T12 > \Delta T_{on}$. Die Min- und Maxwerte der Pumpendrehzahl sind wie bei der Kollektorkreispumpe in den gleichen Grenzen

ebenfalls einstellbar. Damit kann ein Abgleich der Volumenströme des Kollektorkreises und des Speicherladekreises erfolgen. Bei der Testanlage beträgt der eingestellte Minwert 15% und der Maxwert 60% der maximalen Pumpendrehzahl. Damit beträgt die Drehzahl der Pumpe des Speicherladekreises immer etwa 50% der Drehzahl der Pumpe des Kollektorkreises, was in etwa gleiche Volumenströme in beiden Kreisen erzeugt und damit eine optimale Wärmeübertragung erlaubt.

Die Spannungsversorgung der Pumpe des Speicherladekreises 2A01 folgt immer dem Status der Spannungsversorgung der Pumpe des Kollektorkreises 1A01.

6.1.1.2.2 Regelung des Kesselkreises

Die Regelung des Kesselkreises wird durch zwei Flussdiagramme dargestellt Abbildung 43 oben zeigt die Prozedur für die Schaltung der Anforderung des Kessels. Wenn die Temperaturen in Speicher 1T13 oder 1T14 geringer sind als die jeweiligen Solltemperaturen zuzüglich einer Temperaturerhöhung T_{13_on} bzw. T_{14_on} , so wird, sofern die maximal zulässigen Temperatur im Speicher nicht überschritten ist, die Anforderung an den Kessel ($1A11=1$) geschaltet. Dieser Zustand bleibt solange erhalten, bis die Temperatur den jeweiligen Sollwert zuzugliche der vorgenannten Temperaturerhöhung T_{13_on} bzw. T_{14_on} , sowie einer Hysterese T_{13_off} bzw. T_{14_off} , überschritten hat. Dann wird die Anforderung wieder abgeschaltet ($1A11 =0$).

Die Regelung des Volumenstroms durch den Kessel erfolgt gemäß der in Abbildung 43 unten beschriebenen Prozedur. Die Pumpe ist in Betrieb, wenn sowohl die Mindesttemperatur von 50°C im Kessel herrscht als auch der Kessel (2T15) wärmer als der Speicher (2T06) ist. In Abhängigkeit der Speichertemperatur 1T14 wird die Pumpe bei 30% bzw. 100% Drehzahl betrieben. In Zusammenhang mit der kesselinternen Regelung der Vorlauftemperatur bewirkt eine Drosselung der Pumpendrehzahl eine Reduzierung der Kesselleistung.




Abbildung 41: Flussdiagramm Regelung Solarkreis - Kollektorkreis




Abbildung 42: Flussdiagramm Regelung Solarkreis – Speicherladekreis





Abbildung 43: Flussdiagramm Regelung Kesselkreis Anforderung Kessel (oben), Regelung Volumenstrom (unten)




Abbildung 44: Aktoren der ANN-Regelung im realen Testgebäude

6.2 Implementierung der ANN-Regelung im realen Gebäude

Im realen Gebäude wurde die in Abschnitt 5 beschriebene ANN-Regelung implementiert, welche drei Funktionen der konventionellen Regelung ersetzt: Die Steuerung der Vorlauftemperatur des Heizkreises, die Ein-/Ausschaltung der Heizkreispumpe und die Ein-/Ausschaltung des Pelletkessels (Abbildung 44).

6.2.1 Implementierte Netzstruktur und Training der Neuronale Netze

Im realen Testgebäude werden künstliche Neuronale Netzwerke (ANN) als Elemente der Regelung einer solarthermischen Kombianlage eingesetzt. Dabei übernehmen die Neuronale Netze die Aufgabe, den Verlauf der Raumtemperatur im Gebäude sowie den Speicherladezustand zu prognostizieren. Diese Prognosewerte werden in der Regelung benutzt, um den Heizkreis und die konventionelle Nachheizung des Speichers optimal zu steuern (vergl. Abschnitt 5).




Abbildung 45: Netztopologie mit n Input Werten, 2 verborgenen Schichten und einem Ausgangswert

Die Prognosefähigkeit von ANN beruht darauf, dass Daten aus der Vergangenheit über das Verhalten der Anlage und des Gebäudes Informationen über die Zusammenhänge zwischen Prognosewerten und diversen relevanten Eingangsgrößen liefern. Diese Zusammenhänge lernt das ANN und liefert damit ein „black-box“ Modell des Systems.

Im Folgenden werden die beiden Neuronale Netze genauer beschrieben: Die verwendeten Trainingsdaten und der Ablauf des Trainings, die Struktur der Netze und die berechneten Kennzahlen.

Die beiden für die Regelung verwendeten Netze besitzen eine Input-Schicht, zwei verborgenen Schichten mit jeweils zwölf Neuronen und eine Outputschicht mit fünf (Speichertemperatur-Netz) bzw. einem (Raumtemperatur-Netz) Output. Abbildung 45 zeigt beispielhaft ein Netz mit n Eingangsgrößen, zwei verborgenen Schichten mit jeweils m bzw. p Knoten und einem Ausgangswert. (vergl. Abschnitt 3.2). Die gewählte Größe hat sich in den Vorversuchen als guter Kompromiss zwischen Trainingsdauer und Qualität der Kennzahlen der Netze herausgestellt. Ein zu großes Netz neigt zur Überanpassung an die Trainingsdaten und benötigt ein langes Training. Wird das Netz zu klein gewählt, können die Korrelationen in den Trainingsdaten nicht vollständig abgebildet werden.

Beide Netze sind dynamische Netze, d.h. die Outputs werden im nächsten Zeitschritt als Inputs in einer feed-backschleife als Input genutzt. (Abbildung 46). Als Schrittweite für die dynamische Berechnung wurden 15 Minuten gewählt. Die Trainingsdaten, die in minütlichen Intervallen vorliegen, wurden dafür gemittelt. Bei den stündlichen Wetterdaten wurde linear interpoliert.




Abbildung 46: ANN Netz mit zwei verborgenen Schichten, dynamischer Rückkopplung und LSI-Ansatz für die die Prognose der Raumtemperatur (oben) und die Speichertemperaturentwicklung (unten)

Eingabewerte sind Datum, Uhrzeit, Wochentag, welche implizit wichtige Parameter wie Sonnenstand und ggfs. auch zeitliche Muster von zusätzlichen Wärmequellen oder Senken bzw. Wärmeverluste abbilden. Aus einer Wettervorhersage kommen Werte für Außentemperatur, Solare Einstrahlung und Bewölkungsgrad. Die Temperatur des im Gebäude verbauten Kaminofens wird ebenfalls berücksichtigt. Ein für die Regelung wichtiger Eingangswert ist die Vorlauftemperatur des Heizkreises. Für die Prognose der Speichertemperaturen wird der Ausgangswert des ersten ANN, die Raumtemperatur, als Eingangsgröße benutzt. Darüber hinaus auch der Zustand des Pelletbrenners.

Zum Training wurden die Mess- und Wetterdaten der Heizperiode 16/17 verwendet (von 1. Sept 2016 bis 31. Mai 2017). Die aufgezeichneten Daten liegen tageweise (d.h. eine Datei pro Tag) im

.dlb-Format vor. Dieses Format muss mit Hilfe eines Konverter-Programms zunächst in .xml umgewandelt werden. Die Signale der Ein/Ausgänge der PU sind kodiert, sodass man einen Schlüssel für die Umwandlung der Namen und der Zahlenwerte in die richtigen Einheiten benötigt. Unter Nutzung dieses Schlüssels werden monatsweise .txt-Dateien mit einem selbstgeschriebenen Programm erstellt. Es liegen nun die oben beschriebenen 35 Datenspalten im Minutentakt vor. Es ist zu erwähnen, dass es Unstimmigkeiten bei der zeitlichen Aufnahme gibt. So sind die Zeitabstände zwischen den Aufnahmen teilweise etwas unter oder über einer Minute oder es ergeben sich Zeitsprünge von ein bis drei Stunden, in denen keine Daten vorliegen.

Es wurden mit der GUI des Trainingsprogramms WinANN drei batch-Trainings mit jeweils 200 Zyklen durchgeführt. Die Dauer des Trainings des Speichertemperatur-Netzes betrug ca. sieben Stunden, das Training des Raumtemperaturnetzes dauerte etwa halb so lange. Durchgeführt wurde dieses Training auf einem Intel i7-620M Prozessor. Darüber hinaus wurde auch ein rollierendes Trainingssystem implementiert. Das bedeutet, dass nicht mit dem vollständigen Datensatz, sondern nur mit den Daten der letzten 1 bzw. bis 2 Wochen trainiert wird. Die Trainingszeiten reduzieren sich dabei auf die Größenordnung von Minuten. Im realen Regelbetrieb wird dieses Training täglich wiederholt. Damit passt sich das System laufend an sich ggfs. verändernde Bedingungen an. Außerdem werden mögliche jahreszeitliche Änderungen des Systemverhaltens besser abgebildet als bei einem Training mit Jahresdaten.

Für den Test der ANN-Software wurden Trainingsdaten generiert. Diese stammen aus der realen Anlage, welche auch für die Funktionsprüfung der ANN-Software herangezogen werden wird. Ein Softwaretool wurde erstellt, welches erlaubt die vorliegenden Datenfiles in handhabbare Form zu bringen. Es liegen alle relevanten Messdaten der Jahre 2014 bis 2017 im Minutentakt vor. Diese Daten liegen in Form eines Textfiles pro Jahr vor. Soweit Daten fehlen, werden diese durch Duplizieren der vorangehenden Werte komplettiert.

Für die Wetterprognosewerte wurden historische Wetterdaten für die genannten Zeiträume am Standort der Anlage (Marburg) von der Firma meteoblue genutzt. Diese liegen als Zeitreihen in Form eines Textfiles vor.

Die ANN für die Regelung werden für den Heizkreis mit Inputs nach Abbildung 46 trainiert. Die Rohdaten müssen bearbeitet werden, um als Inputs für die ANN verwendet werden zu können. Dazu wurde ein Python-Code erstellt. Zunächst müssen der gewünschte Trainingszeitraum und die gewünschten Input- und Outputvariablen definiert werden.

Neben dem ANN Training für die eigentliche Regelungsaufgabe wurden noch weitere ANN trainiert, um deren Nutzbarkeit für den Regelungsansatz zu untersuchen. Hierfür wurden ANN für die Prognose von Solarertrag der solarthermischen Anlage und der lokalen Außentemperatur am Gebäude generiert.

Für die Bewertung des Solarertrags wurde als Vergleichswert ein Indikator definiert, der auf Basis der vorliegenden Messdaten am Gebäude bewertet werden konnte. Der Input "Solareintrag" wird demnach definiert als „Kollektortemperaturdifferenz multipliziert mit Pumpendrehzahl des Solarkreises“ und ist damit ein Leistungsindikator. Die so definierte Variable schwankt auf minutlichen Skalen stark, was die Handhabbarkeit erschwert. Daher wird für den Solareintrag in allen betrachteten Fällen ein gleitender Mittelwert über die letzten 30 Minuten gebildet und die Kurve somit geglättet (Abbildung 47).




Abbildung 47: Normierte Solareintrag-Variable (Temperaturunterschied am Kollektor multipliziert mit der normierten Pumpendrehzahl) berechnet aus den Rohdaten aufgetragen gegen die Zeit. Oben: Minütliche Werte. Unten: Geglättet, gleitender Mittelwert über 30 Minuten

Für den Validierungsfall wurde die Vorlaufsollltemperatur des Heizkreises als Input gewählt, um die Schwierigkeiten der zeitweise starken Schwankung der tatsächlich gemessenen Werte der Heizkreisvorlauftemperatur zu umgehen.

6.2.2 Bewertung der ANN-Prognosefunktionalität

Neben der Möglichkeit den Speicherladezustand sowie die Raumtemperatur mit ANN zu prognostizieren wurden weitere ANN generiert, mit denen die lokal gemessene Außentemperatur am Gebäude und der Solarertrag der Anlage prognostiziert werden sollte. Die beiden letztgenannten Werte tauchen nicht explizit als Prognosefunktion im ANN-Regelungsansatz auf, sondern werden nur implizit berücksichtigt. Das heißt diese Werte werden nicht explizit berechnet, dennoch spielen sie aufgrund der physikalischen Zusammenhänge eine wichtige Rolle für Speicherladezustand und Raumtemperatur. Die ANN-Prognose berücksichtigt diese Werte implizit indem sie einen Zusammenhang herstellt zwischen den relevanten Daten, die für die Außentemperatur und der Solarertrag verantwortlich sind (z.B. Prognose Solarstrahlung, Uhrzeit für Sonnenstand,) und den direkt für die Regelung notwendigen Werten über Raumtemperatur und Speicherladezustandsentwicklung. Wichtig ist daher zu verstehen, ob ein ANN Ansatz auch in der Lage ist, die lokal gemessene Außentemperatur oder den Solarertrag der Anlage ausreichend genau zu prognostizieren.




Abbildung 48: Korrelation von gemessener Außentemperatur und Vorhersagen von Wetterbericht und ANN..

ren. Nur dann wird eine implizite Berücksichtigung bei der ANN-Regelung erfolgreich sein.

6.2.2.1 Vorhersage der lokal gemessenen Außentemperatur

Die lokal gemessene Außentemperatur, welche durch einen Fühler an der Gebäudehülle gemessen wird, unterscheidet sich von den durch Meteorologen gemessenen oder gar prognostizierten Lufttemperaturwerten. Zum einen liegt das an möglichen Mess- und Prognosefehlern für eine ganz bestimmte Lokalität. Daten aus dem Wetterbericht erfassen zum Beispiel keine kleinteiligen lokalen Einflüsse des Mikroklimas bei der lokalen Temperaturprognose. Zum anderen ergeben sich aber natürlich durch den Montageort des Messfühlers der realen Anlage Abweichungen, welche zum Beispiel durch Windschutz, zeitweise Sonnenbestrahlung oder Abschirmung gegen Abstrahlung an den Himmel oder Erwärmung durch die Gebäudewand begründet sind. Darüber hinaus ergeben sich aber natürlich auch Messfehler bei der lokalen Temperaturmessung.

Um die Lufttemperaturwerte zu prognostizieren, welche die Anlage als Basis für Ihre Regelung nutzt, ist es daher sinnvoll ANN einzusetzen. Hierbei werden tatsächlich gemessene Temperaturwerte mit Temperaturwerten aus einer Wetterprognose bzw. meteorologischen Temperaturmessung korreliert. Hierbei werden neben der eigentlichen Temperatur auch weitere Variablen berücksichtigt, welche auf die lokale Temperaturmessung Einfluss haben. Hierzu zählen neben der Solareinstrahlung, der Windrichtung und Windstärke auch die Uhrzeit des Tages sowie der Tag des Jahres. Letztere Daten liefern Implizit wichtig Informationen über den Sonnenstand und mögliche individuelle, lokale Verschattungssituationen.

Als günstige Netztopologie für eine einstündige Vorhersage hat sich ein (7-10-10-1) statisches Netz bewährt. Das heißt 7 Eingangswerte (Temperaturprognose des Wetterberichts, Uhrzeit + Datum, aktuelle gemessene Temperatur, Windrichtung, Windstärke und globale Solarstrahlung.),




Abbildung 49: Verteilung der Fehler bei der Prognose der Außentemperatur.

Zwei Layer mit je 10 Knoten sowie ein Ausgabewert (Prognose der lokal zu messenden Außentemperatur mit dem Prognosehorizont von einer Stunde). Das Ergebnis zeigt, dass damit die Prognose der lokalen Außentemperatur gegenüber der reinen Wettervorhersage erheblich verbessert werden kann. Die reinen Wettervorhersagewerte mit der tatsächlich gemessenen lokalen Außentemperatur weichen im Mittel um 0,9 K mit einer Standardabweichung von 1,9 K ab. Die mit Hilfe des ANN prognostizierte lokal gemessene Außentemperatur weicht im Mittel um 0,0 K mit einer Standardabweichung von 1,1K ab. Abbildung 49 zeigt, dass das ANN die Werte sowohl zentriert als auch die Fehlerbandbreite reduziert. Die Validierung wurde hier in Bezug auf den Testdatensatz gemacht.

6.2.2.2 Vorhersage des Solarertrags

Als Maß für den Solarertrag wurde das Produkt von Temperaturdifferenz zwischen Kollektorvorkreislauf und Kollektorrücklauf und der Drehzahl der Kollektorkreis-Pumpe gewählt. Um die Qualität der trainierten Netze beurteilen zu können, wurde der mittlere Solarertrag bei Sonnenschein als Referenzgröße definiert. Damit können relative Fehler von Vorhersagen berechnet werden und besser als absolute Werte interpretiert werden.

Das beste Ergebnis wurde mit einem Netz erzielt, das die folgenden Inputs bekommt: Datum und Uhrzeit, Speichertemperaturen unten und oben, Außentemperatur, Bedeckungsgrad und Einstrahlung. Dieses Netz besitzt zwei verborgene Schichten mit jeweils 12 Knoten. Kleinere Netze bilden die Daten ungenauer ab, größere Netze konvergieren später oder gar nicht. Eine Reduktion der Dimensionen des Inputs mit einer Hauptkomponentenanalyse brachte keine Verbesserung der Leistung des Netzes. Hingegen brachte die Aufteilung der Datenanalyse in einen linearen und einen nicht-linearen Anteil eine Verbesserung. Der nicht-lineare Anteil wurde in diesem Fall durch ein ANN-system, der lineare Anteil durch eine konventionelle lineare Approximation dargestellt. (Vergleiche Abschnitt 5.3).




Abbildung 50: Vorhersage der stündlichen Mittelwerte des Solarertrags (Prognosehorizont eine Stunde) mit einem (10-12-12-1) Netz und Vergleich mit den Messdaten

Zusammenfassend lässt sich sagen, dass mit geeigneten Trainingsdaten und -parametern die Dynamik der Messdaten von den neuronalen Netzen gut erfasst werden kann. Mit einem Netz, das




Abbildung 51: Messwerte und ANN-Prognosen der Raumtemperaturen für einen Beispieltag (Training mit dem Datensatz der vergangenen 4 Wochen)




Abbildung 53: Messwerte und ANN-Prognosen der Raumtemperaturen für 3 Beispieltage (Training mit Jahresdatensatz)

auf die Prognose des Solarertrags mit einer Stunde Prognosehorizont trainiert wurde, lag das 80 %-Quantil des relativen Fehlers für den gesamten Datensatz des Jahres 2015 bei 15.2 % (Abbildung 50).

6.2.2.3 Vorhersage der Raumtemperatur




Abbildung 52: ANN-Prognosegenauigkeit der Raumtemperaturen für 100 Tage in der Heizsaison (rollierendes Training mit dem Datensatz der vergangenen 4 Wochen)

Tabelle 8: Vergleich der 90 %-Quantile von unterschiedlichen Trainingszeiträumen

Prognosehorizont/ Trainingszeitraum	1 Stunde	3 Stunden	6 Stunden
1 Woche	0,23 K	0,47 K	0,76 K
4 Wochen	0,23 K	0,47 K	0,93 K
15 Wochen	0,20 K	0,53 K	0,89 K

Die Raumtemperatur wurde mit Hilfe eines dynamischen 10-12-12-1 Netzes prognostiziert. Die Eingangsparameter sind Datum und Uhrzeit, Wochentag, 15-minütliche Mittelwerte: Kaminofenfühler, Vorlauf-Isttemperatur, Wetterdaten: Außentemperatur, Bedeckungsgrad, Einstrahlung (GNI) (Abbildung 46 oben). Trainiert wurde mit einem Datensatz, der die Daten des gesamten Jahres beinhaltet. Die Vorhersage des Netzwerkes für drei Tage des Trainingszeitraumes bei Beginn der Prognose um 9 Uhr vormittags ist in Abbildung 53 gezeigt. Das Netzwerk beschreibt den Verlauf der Raumtemperatur in den ersten Stunden sehr gut. Die größeren Abweichungen gegen Ende des Tages werden vermutlich geringer ausfallen, sobald mehr Messdaten für einen längeren Trainingszeitraum vorhanden sind.

Sehr interessant ist aber, dass auch ein nur vierwöchiges Training ähnlich gute Ergebnisse bringt (Abbildung 51). Die Prognosegenauigkeit für ein rollierendes Training mit täglicher Betrachtung der jeweils 4 Wochen zurückliegenden Daten zeigt Abbildung 52. Ausgewertet wurden hierbei 100 Tage aus der Heizperiode. Während der ersten 2 Stunden kann in 95% der Tage die Raumtemperatur mit einer Abweichung von weniger als ca. 0,3 K prognostiziert werden. Dies ist eine bemerkenswert gute Prognosegenauigkeit insbesondere weil natürlich auch vom ANN nicht prognostizierbare Effekte auftreten. Dazu gehört zum Beispiel das Öffnen des Fensters oder zusätzlicher Wärmeeintrag durch ausgiebige Koch- und Backaktivitäten im Haushalt. Dazu kommen noch Ungenauigkeiten in der Prognose der Wetterdaten.

Tabelle 8 zeigt Prognosegenauigkeiten für verschiedene Trainingszeiträume und Prognosehorizonte für das 90% Quantil. Es ist offensichtlich, dass auch mit kurzen Trainingszeiträumen gute Prognosegenauigkeiten erzielt werden können. Der Trainingszeitraum sollte aus Gründen des Rechenaufwandes so kurz wie möglich gewählt werden. Dieser Zeitraum muss aber alle relevanten Ereignisse enthalten, die relevant für die Prognose sind. So wurde im realen Testgebäude der Trainingszeitraum auf 4 Wochen festgelegt, weil der Effekt des Kaminofens nur bei einem solchen Betrachtungszeitraum regelmäßig beim Training berücksichtigt werden kann. Im Falle einer rein automatischen Heizung ohne unregelmäßige manuelle Zuheizung reicht aber ein Zeitraum von einer Woche völlig aus.




Abbildung 54: ANN-Prognosegenauigkeit der Speichertemperatur für rollierendes Training mit dem Datensatz der vergangene 4 Wochen

6.2.2.4 Vorhersage der Speichertemperaturen

Die Erfahrungen, die mit den Netzen zur Vorhersage des Solarertrags und Raumtemperatur bezüglich Netzwerkstruktur und Trainingsparametern gemacht wurden, konnten bei der Vorhersage der Speichertemperaturen bestätigt werden. Ein dynamisches Netzwerk mit zwei verborgenen Schichten mit jeweils 12 Knoten ist gut geeignet, um die Daten angemessen zu beschreiben. Mit reinem Batch-Training werden gute Trainingsergebnisse erzielt. Es hat sich als hilfreich erwiesen, alle vorhandenen Speichertemperaturen als Outputs und im Fall des dynamischen Netzes als dynamischen feed-back Werte zu verwenden, um beim Training die maximal verfügbare Information über den Speicherzustand zur Verfügung zu stellen. Ein 15-Minuten-Intervall erscheint für das Training sinnvoll.

Für die Prognose der Speichertemperaturen wurden die folgenden Inputs verwendet: Datum, Uhrzeit, Wochentag, Brennerzustand, Raumtemperatur, Oberflächentemperatur des Kaminofens, Vorlauf-Isttemperatur, Außentemperatur, Bedeckungsgrad, Einstrahlung (Abbildung 46 unten).. Bei einem Start der Prognose um 9 Uhr morgens liegt das 80 %-Quantil der Fehler der Vorhersage der oberen Speichertemperatur in den ersten sechs Stunden unter 10 K (Abbildung 54). Der

Trainingszeitraum von 4 Wochen eignet sich gut, um ausreichende Genauigkeit zu bekommen und Rechenaufwand zu begrenzen.

Zu beachten ist an dieser Stelle, dass Effekte wie Warmwasserzapfung vom ANN kaum prognostiziert werden können. Darüber hinaus pflanzen sich Fehler aus der Prognose der Raumtemperatur fort, da diese Werte als Inputdaten des ANN für die Speichertemperatur genutzt werden. Dennoch zeigt sich, dass der Ansatz noch ausreichende Genauigkeit bietet um einerseits energetische Vorteile zu generieren (Abschnitt 7.4) und andererseits einen robusten Regelbetrieb sicherzustellen (Abschnitt 6.3).

6.2.2.5 Erkenntnisse zu ANN Training

Bei allen zur Prognose untersuchten ANN-Netzen in Abschnitt 6.2.2 wurden mit reinem Batch-Training gute Ergebnisse erzielt. Die Erhöhung des Trainingsparameters ‚Korrekturfaktor der Gewichte‘ führt zu einer schnelleren Konvergenz ins Optimum und kann zur Beschleunigung des Trainings genutzt werden. Die Aufteilung der Messdaten in einen Trainingsdatensatz und einen Validierungsdatensatz ermöglicht eine Kontrolle der Outputs des Netzwerkes. Das Problem einer Überanpassung wird damit vermieden, denn es steht ein geeignetes Kriterium zum Abbruch des Trainings zur Verfügung – sobald die Residuen im Validierungsdatensatz nicht mehr abnehmen, wird das Training beendet.

Die besten Ergebnisse liefern dynamische Netze mit zwei verborgenen Schichten und Neuronenzahlen im niedrigen zweistelligen Bereich – die Beschreibung der Daten ist damit gut und ein vollständiges Training kann in weniger als einer Stunde durchgeführt werden. Es wurden viele erfolgreiche Trainings mit einem einjährigen Trainingszeitraum durchgeführt. Besonders wichtig ist aber die Erkenntnis, dass mit einem auf vier Wochen reduzierten rollierenden Trainingszeitraum akzeptable Prognosegenauigkeiten erzielt werden. Als Zeitschritte zwischen den einzelnen Prognosewerten wurden 60 Minuten und 15 Minuten gewählt. Beide eignen sich gut für das Training und die Beschreibung der Daten.

6.2.3 Eingabe-/Ausgabeschnittstelle ANNsoftware zur vorhandenen Regelung

6.2.3.1 Bestandsregler SUNGOvario

In der Feldtestanlage, die für den Testlauf der ANN-Regelung verwendet wurde, kommt der Solarregler SUNGOvario der Firma Prozeda GmbH zum Einsatz. Der Solarregler besteht im Wesentlichen aus einem Bedienteil und einer Anschlusseinheit. In dem Bedienteil, welches im Folgenden auch Kontrolleinheit (engl. Control Unit CU) bezeichnet wird, sind die CPU, der Speicher und ein vollgrafisches Touch-Display untergebracht. Die Anschlusseinheit (engl. PowerUnit PU) hingegen ist für das Erfassen der diversen Sensorwerte und die Ansteuerung der Aktoren zuständig. Beide

Einheiten sind über ein SPI-BUS-System³ aneinander gekoppelt. Die Bedieneinheit kann durch das BUS-System getrennt von der Anschlusseinheit installiert werden.

Um die ANN-Regelung mit den ANN-Algorithmen in der Feldtestanlage testen zu können, wurde der Regler so verändert, dass es möglich wurde jeden beliebigen Ausgang extern anzusteuern. Die Eingangssignale des Reglers konnten ebenfalls einer externen Regeleinheit zur Verfügung gestellt werden.

6.2.3.2 Anforderungen der Modifikation des Bestandsreglers für die Implementierung der ANN-Regelung

Für die erfolgreiche Implementierung der ANN-Regelung in der Feldtestanlage musste einerseits die Möglichkeit geschaffen werden, einen sicheren und fehlerfreien Betrieb der Anlage zu gewährleisten, andererseits aber auch der ANN-Regelung einen kontrollierten Eingriff in den Anlagenbetrieb ermöglicht werden. Das heißt, die ANN-Regelung soll durch eine Eingriffsmöglichkeit die Steuerung und Kontrolle der Anlage übernehmen können, sofern aber sicherheitsrelevante oder kritische Situationen entstehen, muss, wie in der ursprüngliche Regelung, eine Abschaltung verschiedener Ausgänge erfolgen. Hierbei müssen folgende Punkte beachtet und berücksichtigt werden:

- Permanente Überwachung aller sicherheitsrelevanten Parameter und Sicherheitsfunktionen
- Möglichkeit eines gezielten Ein- und Ausschaltens der ANN-Regelung per Software
- Ansteuerung der Aktoren durch die ANN-Regelung mit gleichzeitiger Unterdrückung der Ansteuerung durch die Bedieneinheit
- Kritische Schaltzustände in der Anlage dürfen nicht auftreten
- Datenlogging der Sensoren und Aktoren
- Hardwareseitige Deaktivierungsmöglichkeit der ANN-Regelung für den Anlagenbesitzer im Falle einer Störung der Anlage

³ Serial Peripheral Interface




Abbildung 55: Blockschema der Implementierung der I/O Schnittstelle

6.2.3.3 Umsetzung der Anforderungen

Die Modifikation des Bestandsreglers in der Feldtestanlage wurde durch den Hersteller des Reglers wie folgt umgesetzt:

- Austausch der bestehenden Anschlusseinheit (PU) durch eine neue, modifizierte Anschlusseinheit
- Erweiterung der neuen Anschlusseinheit durch einen Kommunikations-Port und durch einen Hardwareschalter
- Installation eines Koppelmoduls, das durch die Anschlusseinheit über den ANN-Rechner angesprochen werden kann

Abbildung 55 zeigt das Blockschema der Umsetzung der Implementierung. Im Folgenden werden die Änderungen und Besonderheiten der Komponenten in Kürze beschrieben.

6.2.3.3.1 Kontrolleinheit CU

Die bestehende Kontrolleinheit bleibt in der Anlage bestehen. Auf ihr sind alle Anlagenparameter und die Anlagen-Konfiguration gespeichert. Auf der CU werden im normalen Betrieb der Anlage folgende Sicherheitsfunktionen und Temperaturbegrenzungen realisiert:

- Maximaltemperaturbegrenzung des Speichers
- Frostschutz
- Maximaltemperaturbegrenzung des Heizkreises

- Kollektorkühlung
- Speicherkühlung
- Thermische Desinfektion
- Überwachung der Mindestkesseltemperatur

Diese Funktionen und Grenzwerte werden nach der Einbringung der modifizierten Anschlusseinheit (PU) weiter durch die Kontrolleinheit überwacht. Diese Sicherheitsfunktionen fragen in der Regel Temperaturwerte ab und vergleichen diese mit Maximal- oder Minimalgrenzen. Überschreitet oder unterschreitet ein Sensorwert den ihm vorgegebenen Grenzwert, so wird der dem Sensor zugeordnete Aktor ausgeschaltet. Dies wird im Falle der ANN-Regelung nicht mehr möglich sein, da im ANN-Betrieb die CU die Aktoren nach den ihr programmierten Funktionen ausschaltet, der Aktor aber durch das Koppelmodul auf Ansteuerung durch die ANN-Regelung geschaltet ist. Daher ist es notwendig, dass die Sicherheitsfunktionen, welche die Ausgänge des ANN-Regelungsalgorithmus betreffen auch im ANN Regelungsalgorithmus hinterlegt werden.

6.2.3.3.2 Anschlusseinheit PowerUnit PU

Die in der Feldtestanlage installierte Anschlusseinheit (PU) wurde durch eine neue, modifizierte Anschlusseinheit (PU) ersetzt. Die ursprüngliche Kontrolleinheit CU bleibt bestehen. Nach wie vor laufen auf der Kontrolleinheit (CU) die ursprünglich programmierte Steuerung und Regelung. Auf der Kontrolleinheit (CU) bleiben alle Funktionen bestehen. Die Kommunikation findet wie gewohnt über den SPI-Bus statt. Auf dem SPI-Bus werden durch die Kontrolleinheit (CU), die als MASTER fungiert, die Daten der Sensoren von der Anschlusseinheit (PU) abgefragt und über den SPI-Bus Stellgrößen für die Aktoren vorgegeben. Hierfür synchronisiert sich die Kontrolleinheit (CU) mit der Anschlusseinheit (PU) über ein sogenanntes serial-clock-Signal SCLK. Die Anschlusseinheit (PU) ist auf dem SPI-BUS der Slave-Device. Beide Devices sprechen über ein MOSI (englisch Master Output, Slave Input) und MISO (englisch Master Input, Slave Output) miteinander. Das SCLK Signal synchronisiert alle 250ms. Diese Taktung darf nicht unterbrochen werden, da sonst die Kommunikation nicht mehr funktioniert und ein Fehler auftritt.

Die neue Anschlusseinheit (PU) wurde hardwareseitig mit einer weiteren Schnittstelle ausgerüstet. Die Umsetzung erfolgte mit einer herkömmlichen seriellen RS232 Schnittstelle, da hierfür die Kommunikationsprotokolle einfach sind und jeder Rechner über die Möglichkeit verfügt, dieses Protokoll zu lesen. Die Betriebssoftware der PowerUnit wurde um die Funktionalität der Kommunikation über das Koppelmodul und die variable Übernahme der Ansteuerung der Ausgänge vom Koppelmodul erweitert. Das Koppelmodul kann als Master diese neue Schnittstelle bedienen und übernimmt auch das Senden von Sensor- und Aktordaten der Anschlusseinheit zum ANN-PC. Über das Koppelmodul können so auch die Aktordaten gesetzt werden.

Eine neue Funktion der Anschlusseinheit (PU) ist das Überschreiben der Werte der Kontrolleinheit (CU) im Falle der aktiven ANN-Regelung, die sogenannte „Overridefunktion“. Ist die ANN-Regelung aktiv, so werden die über den SPI-Bus übertragenen Stellgrößen für Aktoren von der ANN-Regelung überschrieben. Die Anschlusseinheit (PU) reagiert daher nicht mehr auf die Stellgrößen, die durch die Kontrolleinheit (CU) geregelt werden. Findet keine Kommunikation zwischen PowerUnit und Koppelmodul statt, so schaltet eine „Fallbackfunktion“ softwareseitig automatisch auf die Steuerung und Regelung der Kontrolleinheit (CU) zurück. Kommt die Kommunikation innerhalb von 5 Minuten wieder zustande, schaltet die Anschlusseinheit (PU) auf die Steuerung und Regelung über den ANN-PC. Bleibt die Kommunikation länger als 5 Minuten unterbrochen, so wird das Überschreiben vollständig zurückgesetzt. Diese Funktion verhindert, dass bei einem Ausfall des ANN-PCs die Anlage in einen unkontrollierten Zustand gerät und kann auch für ein aktives Umschalten auf die ursprüngliche Regelung durch den Betreiber der Anlage genutzt werden. Hierzu muss lediglich die Verbindung zwischen ANN-PC und Bus unterbrochen werden.

6.2.3.3.3 Koppelmodul

Ein Koppelmodul, welches im Wesentlichen aus einer modifizierten Kontrolleinheit (CU) besteht, wird über die serielle Schnittstelle an der neuen Anschlusseinheit (PU) angeschlossen. Dieses Koppelmodul übersetzt die Daten von und zum ANN-PC. Durch den ANN-Rechner werden zur Kontrolleinheit (CU) hauptsächlich Stellgrößen für Aktoren übertragen. Zum ANN-PC müssen aber auch die Sensorwerte übertragen werden.

Das Koppelmodul wird um die Funktionalität erweitert, die gesamten Daten an den ANN-PC zu übertragen. Die bestehende Kontrolleinheit (CU) zeichnet nur die Daten auf, die auf dem SPI-BUS übertragen werden und speichert diese auch auf der installierten MicroSD Karte. Die Daten des Koppelmoduls bzw. der ANN-Regelung werden durch die Kontrolleinheit (CU) nicht gesehen und demnach auch nicht aufgezeichnet. Um auch diese Daten erfassen zu können, werden die gesamten Datensätze vom Koppelmodul an den ANN-PC regelmäßig übertragen und dort aufgezeichnet. Diese Daten können zur Auswertung abgerufen werden.

Das Koppelmodul wird neben der Funktionalität der Übersetzung der Kommunikationsdaten auch alle aktuellen Funktionen und Einstellungen auf einem Display darstellen. Der Anlagenbesitzer kann hierdurch die Zustände in der Anlage vor Ort überwachen.

6.2.3.3.4 Sicherheitsfunktionen auf dem ANN-Rechner

Da die Kontrolleinheit (CU) die Ausgänge, die durch die ANN-Regelung bedient werden, nicht mehr überwachen kann, müssen diese Sicherheitsfunktionen auf dem ANN-PC realisiert werden. Als sicherheitsrelevante Funktionen wurden die folgenden drei identifiziert:

Maximaltemperaturbegrenzung des Speichers

Abschaltung der Nachheizung, der Solarkreisumpen, der Heizkreispumpe und der Frischwasserpumpe bei Überschreitung einer Maximaltemperatur an einem der Temperaturfühler am Speicher.

Maximaltemperaturbegrenzung Heizkreis

Abschalten der Heizkreispumpe und Schließen des Mischventils bei Überschreitung einer maximalen Vorlauftemperatur im Heizkreis von 65°C, so dass kein weiteres heißes Wasser in den Heizkreis gelangt. Bei dieser Funktion müssen besondere Sicherheitsvorkehrungen getroffen werden. Der Motor des Mischventils, der für das Auf- und Zufahren verantwortlich ist, wird über zwei Spulen angesteuert. Hierfür werden zwei Ausgänge auf der PU belegt. Auf der CU sind softwareseitig Schaltungen programmiert, so dass bei einem geschalteten Ausgang der andere verriegelt ist. Ein gleichzeitiges Ansteuern beider Ausgänge ist nicht möglich. Dies schützt den Motor vor einem Defekt.

6.2.3.3.5 Regelungsfunktionen auf dem ANN-Rechner

Neben den sicherheitsrelevanten Funktionen werden auf dem ANN-Rechner weitere, neue Funktionen hinterlegt, die auf der CU (im ursprünglichen Regelungsalgorithmus) nicht vorhanden waren. Diese sind in Abschnitt 5 detailliert beschrieben.

6.3 Verhalten der ANN-Regelung im realen Gebäude

Der ANN-Regelungsalgorithmus wurde im realen Testgebäude von September 2017 bis April 2018 erfolgreich betrieben. Zum Teil wurden parallel zum ANN-Betrieb auch Regelparameter aus der konventionellen Regelung aufgezeichnet. Dies betrifft insbesondere die Vorlauftemperatur des Heizkreises. Damit kann die tatsächlich von der ANN-Regelung im Gebäude realisierte Vorlauftemperatur mit der Vorlauftemperatur, die die ursprüngliche Regelung unter den gleichen Bedingungen generieren würde, verglichen werden.

Abbildung 56 zeigt einen Zeitraum von 5 Tagen Anfang April 2018. Auf dem oberen Diagramm ist der Verlauf der Vorlauftemperaturen von ANN-Regelung und konventioneller Regelung zu sehen. Die konventionelle Regelung besitzt neben der Heizkurvenregelung zusätzlich eine Korrektur der Vorlauftemperatur, wenn die Raumtemperatur den Sollwert überschritten hat. Dies zeigt sich in den sichtbaren Sprüngen des roten Graphen.

Auffallend ist zunächst, dass die Vorlauftemperatur der ANN-Regelung eine wesentlich höhere Dynamik als die der konventionellen Regelung zeigt. Morgens, wenn die Regelung keine ausreichende Erwärmung durch passive solare Einstrahlung erwartet, wird die Vorlauftemperatur auf

den maximal zulässigen Wert hochgezogen, um die gewünschte Raumtemperatur zügig zu erreichen. Sobald die gewünschte Raumtemperatur erreicht ist (Graph in der Mitte), sinkt die Vorlauftemperatur ab. Reicht die prognostizierte passive solare Einstrahlung aus, um die Raumtemperatur mindestens zu halten, schaltet der Heizkreis sogar komplett ab. Der untere Graph zeigt die Temperatur des Kollektorfeldes. Die Höhe der Kollektortemperatur ist ein Indikator für die Intensität der solaren Einstrahlung.

Durch Berücksichtigung der Wettervorhersage und deren individueller Auswirkung auf die Raumtemperatur scheint die ANN-Regelung damit in der Lage zu sein, noch besser die Raumsolltemperatur erreichen und halten zu können als die konventionelle Regelung. Dies konnte mit Hilfe von Vergleichen der beiden Regelungsansätze in einer virtuellen Umgebung belegt werden (Abschnitt 7.3.5).




Abbildung 56: Heizkreisvorlauftemperaturen von konventioneller Regelung und ANN-Regelung (oben), Soll- und Istwert der Raumtemperatur mit ANN Regelung (mitte) und Kollektortemperatur (unten)

7 Energetische Bewertung

Während die Funktionalität im realen Gebäude überprüft wurde, findet die energetische Bewertung in einem simulierten Gebäude statt. Nur so kann mit vertretbarem Aufwand und ausreichender Genauigkeit eine quantitative Aussage über Energieflüsse getroffen werden.

In einem realen Gebäude besteht zum einen die Schwierigkeit, Wärmemengen, Strahlung, Temperaturen und Volumenströme ausreichend genau zu erfassen. Zum anderen, und dieser Aspekt ist als noch viel kritischer einzustufen, ist es außerordentlich schwierig, Referenzwerte zu ermitteln, mit denen die ANN Regelung zu vergleichen wäre. Entweder müsste man zwei identische Gebäude am gleichen Standort mit identischen Nutzerverhalten betreiben um eine konventionelle Regelung mit der ANN Regelung zu vergleichen. Oder man rechnet aus dem Verhalten des gemessenen Gebäudes mit einer ANN Regelung zurück auf das Verhalten des Gebäudes mit konventioneller Regelung. Im ersten Fall ist nachvollziehbar, dass damit enormer zusätzlicher Aufwand entstünde, wenn die genannte Voraussetzungen denn überhaupt erreicht werden können. Im zweiten Fall ist auch eine Simulation notwendig.

Wenn die energetische Bewertung von Beginn an auf einer Simulation basiert, besteht der entscheidende Vorteil dass damit auch relativ einfach andere Randbedingungen untersucht werden können (z.B. andere Gebäude, Standorte, Nutzerverhalten).

7.1 Modellierung des Gebäudes

Das Modell des Gebäudes und des Anlagensystems in Dymola besteht aus 6 Hauptkomponenten: Gebäudemodell, thermischer Speicher, Solarkreis, Kesselkreis, Trinkwarmwasserkreis und Heizkreis. Die Regelung des Systems in dem Modell wird durch 5 konventionelle Regler realisiert.

Tabelle 9: U-Werte der Elemente der Gebäudehülle im Gebäudemodell

Wärmedämmstandard	Variante I	Variante II	Variante III
Hausumschlagkonstruktion	U-Wert (W/(m ² · K))	U-Wert (W/(m ² · K))	U-Wert (W/(m ² · K))
Außenwände	0,24	0,30	1,20
Dach	0,20	0,29	0,80
Fußboden	0,20	0,28	1,08
Innenwände	0,20	1,28	0,80
Decke	0,80	0,86	1,08
Fenster	0,80	1,0	2,80

Die Wetterdaten und die Daten über den Verbrauch von Trinkwarmwasser, die für die Simulation des Modells verwendet werden, liest das Modell aus externen Dateien. Die Wetterdaten wurden mit der Software Meteonorm V7.1.11.24422 der Firma Meteotest AG, erzeugt.

Um die Simulationszeit zu reduzieren, wurde das Modell im Vergleich zu der realen Situation ver-




Abbildung 57: Modell des Gebäudes und des Anlagensystems in Dymola

einfacht. Beispielsweise gibt es in dem Modell keinen Wärmeaustausch zwischen der Pumpe und dem Arbeitsfluid, die Fließgeschwindigkeit in den Rohrleitungen ist immer 1m/s.

Für die Simulationen wurde ein Modell eines zweigeschossigen Einfamilienhauses verwendet, das einen Heizkreis mit Heizkörper enthält. Das Gebäudemodell wurde intern am Fraunhofer ISE als Teil der ISELib-Bibliothek [7] entwickelt.

Die Bodenfläche auf jeder Etage beträgt 70 m². Die gesamte beheizte Fläche A_{SH} im Hausmodell beträgt 140 m². Die gesamte Außenwandfläche beträgt 168,54 m². Die Fensterfläche an den Außenwänden beträgt 17 m² an der Südaußenwand, 20,4 m² an der Westaußenwand, 12 m² an der Ostaußenwand und 0,8 m² an der Nordaußenwand. Die Lüftungsluftwechselrate $n_{ventilation}$ in dem Gebäudemodell beträgt 0,4 1/h und die Infiltrationsluftwechselrate $n_{infiltration}$ 0,12 1/h. Der innere Wärmegewinn beträgt 2,86 W/m².




Abbildung 58: Innere Struktur des Gebäudemodells




Abbildung 59: Gebäudemodell in Dymola

Im Vergleich zu dem realen Referenzgebäude hat das Gebäudemodell eine vereinfachte Struktur, kleinere Außenwandflächen (ca. 55 %). Die Fensterflächen im Gebäudemodell sind nahezu identisch mit denen im realen Gebäude. Im Referenzgebäude beträgt der Anteil der Fensterflächen an den gesamten Fassadenflächen 19,7%. Dieser Anteil liegt im Gebäudemodell bei 22,9 %.

Um den Regelprozess in verschiedenen Gebäuden mit unterschiedlichen Heizanforderungen und Betriebsbedingungen zu bewerten, wurden 3 unterschiedliche Wärmedämmstandards für das Hausmodell benutzt. Die Parameter im Wärmedämmstandard II wurden in Anlehnung an das reale Gebäude definiert. Tabelle 9 zeigt die U-Werte der Gebäudehüllenkonstruktionen der 3 Varianten. Dabei entsprechen die Varianten I und II den Werten von EFH Neubauten der letzten 10 Jahre, Variante III entspricht einem typischen Einfamilienhaus aus den 50-er Jahren.

Um die Heizungssysteme für die 3 Varianten zu parametrieren, wurde vor der Simulation zunächst die Normheizlast des Hausmodells berechnet. Die Normheizlast des Hausmodells in den 3 Varianten wurde nach DIN EN 12381 ermittelt. Hierbei wurde 20°C und 12°C als Norm-Innen- bzw. Außentemperatur verwendet. In Variante I besitzt das Gebäude eine Fußbodenheizung. Wie bei dieser Variante heute üblich, wurde auf eine Nachtabsenkung der Raumtemperatur verzichtet. In den Varianten II und III wird in der Zeit von 22:00-6:00 der Zielwert der Raumtemperatur auf 17°C abgesenkt. In den Varianten II und III ist das Gebäude mit Heizkörpern ausgestattet. Tabelle 10 zeigt

Tabelle 10: Berechnete Normheizlast des Gebäudes für die untersuchten Varianten

Variante	Normheizlast (kW)
I	7,12
II	13,59
III	24,62

die berechnete Normheizlast des Hausmodells in den 3 Varianten.

Abbildung 58 zeigt die innere Struktur des Gebäudemodells (Abbildung 59). Damit lassen sich die Wärmeströme bilanzieren. Berücksichtigt werden solare Wärmegewinne, Transmissionswärmeverluste, Belüftungs- und Infiltrationswärmeverluste, interne Wärmegewinne und Wärmeverbrauch des Gebäudes. Abbildung 59 zeigt wie das Gebäude hydraulisch mit dem Heizungssystem verbunden ist und die Anbindung an die extern zur Verfügung gestellten Wetterdaten.

7.1.1 Thermischer Speicher

Das Speichermodell in Dymola wurde auf Basis des Modells "Buffer Storage" in ISELib [7] entwickelt. Dieses Modell hat insgesamt 10 Schichten und ermöglicht eine geschichtete Ladung und Entladung. Abbildung 60 zeigt die innere Struktur des Speichermodells.

Das Speichermodell ist mit 4 Komponenten gekoppelt: Solarkreis, Kesselkreis, Trinkwarmwasserkreis und Heizkreis. Um einen hohen Kollektorwirkungsgrad zu erreichen, ist die Rücklaufrohrleitung des Solarkreises am untersten Teil des Speichers angeschlossen. Die Vorlaufrohrleitung des Kesselkreises ist am obersten Teil des Speichers angeschlossen, und das erwärmte Fluid mit hoher Temperatur strömt in den oberen Teil des Speichers. Das Fluid mit der hohen Temperatur im oberen Teil des Speichers wird dem Heizkreis und dem Trinkwarmwasserkreis zugeführt, der kalte Rücklauf wird zurück in den unteren Teil des Speichers geleitet.




Abbildung 60: Innere Struktur des thermischen Speichers in Dymola




Abbildung 61: Solarkreis in Dymola

7.1.2 Solarkreis

Der Solarkreis besteht aus 2 Unterkreisen: Kollektorkreis und Speicherkreis. In Jedem Unterkreis gibt es eine Pumpe. Die 2 Unterkreise sind durch einen Wärmeübertrager thermisch gekoppelt. Abbildung 61 zeigt die Struktur des Solarkreises und die Verbindung zwischen dem Solarkreis und dem thermischen Speicher. Das Arbeitsmedium im Speicherkreis ist Wasser. Im Kollektor und dem Kollektorkreis wird ein Gemisch aus Wasser und Glykol als Arbeitsfluid verwendet.

Wegen der zeitweise hohen Temperatur des Arbeitsmediums im Solarkreis können hier signifikante Wärmeverluste entstehen. Dies wurde berücksichtigt indem Rohrleitungskomponenten mit entsprechenden Wärmeverlusten in diesem Kreis verwendet werden. Die in der Simulation verwendete Rohrleitung- und Wärmeübertragerkomponenten stammen aus den Modellen "Pipe" und "HeatExchanger" in der Building Library [8].

Zur Modellierung der Solarthermiekollektoren wurde die Flachkollektor-Komponente EN12975

Tabelle 11: Parameter der Solarkollektor-Komponente

Parameter	Wert
$A_{ap,col}$ (m ²)	2,02
η_0	0,818
c_1 (W/m ² ·K)	3,47
c_2 (W/m ² ·K ²)	0,0101




Abbildung 62: Kesselkreis in Dymola

nach den Prüfnormen DIN EN12975 aus der Bibliothek „Buildings Library“ verwendet [8]. In der Simulation erhält die Komponente Wetterdaten vom Wetterdatenleser und die solaren Gewinne und Wärmeverluste des Kollektors werden entsprechend ermittelt. Tabelle 11 zeigt die wichtigen Parameter der Flachkollektor-Komponente. Im Modell werden 7 Solarkollektoren verwendet, die Gesamtfläche der Solarkollektoren beträgt 14,14 m².

7.1.3 Kesselkreis

Durch den Kesselkreis wird der obere Teil des Speichers auf einem Mindesttemperaturniveau gehalten, welches für die Versorgung des Heizkreises und des Trinkwarmwassers notwendig ist. Dieses variiert und hängt vom vorgegebene Lastprofil der Warmwasserzapfung sowie dem aktuellen Wärmebedarf des Gebäudes ab. In Abbildung 62 ist der Kesselkreis im Dymolamodell dargestellt. Im Kesselkreis wurden auch Rohrleitungskomponenten mit Wärmeverlustberechnung verwendet, um diese zu bewerten.




Abbildung 64: Trinkwarmwasserkreis in Dymola

7.1.4 Trinkwarmwasserkreis

Der Trinkwarmwasserkreis besteht aus 2 Unterkreisen: Trinkwasserentnahmekreis und Speicherkreis, die durch einen Wärmeübertrager thermisch gekoppelt sind. Das Trinkwarmwasserzapfprofil liest das Modell aus der externen Datei „DHW-Profil“. Die Zieltemperatur des Trinkwarmwassers ist 45°C. Abbildung 64 zeigt den Aufbau des Trinkwarmwasserkreises.




Abbildung 63: Kaltwassertemperaturprofil




Abbildung 65: Heizkreis in Dymola

7.1.4.1 Trinkwarmwasser-Lastprofile

Das Trinkwarmwasser-Lastprofil für das Einfamilienhaus wurde mit DHWcalc erstellt. DHWcalc ist eine Software, die zur Erstellung von Warmwasserprofilen entwickelt wurde [9]. Der Verlauf der Temperatur des kalten Wassers ist in Abbildung 63 dargestellt und errechnet sich nach Gleichung (7.1).

$$T_{CW}(\text{°C}) = T_{CW,AV} + dT_{CW,AMP} \cdot \sin\left(\frac{360(t + 24 \cdot (273,75 - dt_{CW,shift}))}{8760}\right) \quad (7.1)$$

7.1.5 Heizkreis

Im Heizkreis müssen das Mischventil und die Pumpe gesteuert werden, um die Zielvorlauftemperatur im Heizungssystem zu erreichen. Diese Zieltemperatur wird in der konventionellen Regelung mit einer konventionellen Heizkurve berechnet. Der ANN-Regler ist in der Lage, die Heizkurve automatisch zu generieren und den Nachheizbedarf zu reduzieren. Die für die Simulation und den Regelungsprozess benötigten Daten liest das Modell aus externen Dateien. Der Aufbau des Heizkreises ist in Abbildung 65 dargestellt.




Abbildung 66: Wetterdaten Jahr 2011 Freiburg im Breisgau

Im Hausmodell mit Wärmedämmstandard I, II und III wurden verschiedene Heizsysteme zur Deckung des Wärmebedarfs eingesetzt. Wichtige Parameter der Heizungssysteme sind in Tabelle 12 zusammengefasst.

7.1.6 Wetterdaten

Die in der Simulation verwendeten Wetterdaten sind die Wetterdaten aus dem Jahr 2011 für den Ort Freiburg im Breisgau. Abbildung 66 zeigt die monatlichen Durchschnittswerte der Außentemperatur, der diffusen und der direkten Solarstrahlung in diesem Jahr.

Tabelle 12: Heizungssysteme im Gebäudemodell

Variante	I	II	III
Heizungstyp	Fußbodenheizung	Heizkörper	Heizkörper
T_{VL} (°C)	35	45	70
T_{RL} (°C)	27	35	50
n	1,1	1,3	1,3
Nennleistung (kW)	7,5	14	25

7.2 Regelung im Simulationsmodell

Um energetische Effekte zu bewerten, wurden sowohl eine konventionelle Regelung als auch eine ANN Regelung in der Modelumgebung implementiert

7.2.1 Konventionelle Regelung

Im Modell des Gebäudes und des Anlagensystems in Dymola wurde eine konventionelle Regelung für den Solarkreis, Kesselkreis, Trinkwarmwasserkreis und Heizkreis integriert. In der Simulation lesen diese Regler die benötigten Daten aus dem Modell und den externen Dateien und generieren die Reglungssignale.

7.2.1.1 Konventionelle Regelung des Solarkreises

Die konventionelle Regelung des Solarkreises wird durch den Regler in Abbildung 67 realisiert.




Abbildung 67: Konventioneller Regler des Solarkreises




Abbildung 69: Konventioneller Regler des Trinkwarmwasserkreises




Abbildung 70: Konventioneller Regler des Mischers im Heizkreis

wieder ausgeschaltet wird. Dieses Verhalten wurde im Modell mit einem entsprechenden zeitlichen Leistungsverlauf abgebildet.

Um die Lebensdauer des Kessels zu verlängern, sollte er nicht übermäßig häufig ein- und ausgeschaltet werden. Nach jedem Einschalten des Kessels ist dieser für mindestens 3000 s (50 min) in Betrieb, auch wenn die Temperatur in der obersten Schicht des Speichers bereits 65°C überschritten hat.




Abbildung 71: Konventionelle Heizkurve

7.2.1.3 Konventionelle Regelung des Trinkwarmwasserkreises

Der Volumenstrom der Pumpe im Speicherkreis des Trinkwarmwasserkreises wird von einem PID-Regler geregelt, der den Sollwert (45°C) mit dem Istwert der Vorlauftemperatur im Trinkwasserentnahmekreis vergleicht und die Regelungssignale generiert (Abbildung 69). Tabelle 13 zeigt die Parameter des PID-Reglers.

7.2.1.4 Konventionelle Regelung des Heizkreises

Im Heizkreis befinden sich zwei PID-Regler, die den Mischer und die Pumpe kontrollieren. Der Regler des Mixers berechnet den Sollwert der Vorlauftemperatur und vergleicht diesen Wert mit dem Istwert der Vorlauftemperatur im Heizkreis, um das Regelungssignal zu generieren. Der in Abbildung 70 dargestellte Regler verwendet eine Heizkurve zur Bestimmung der Ziel-

Tabelle 13: Parameter des PID-Reglers im Trinkwarmwasserkreis

Parameter	Wert
k	0,1
T_i (s)	1000
T_d (s)	1,0




Abbildung 72: Konventioneller Regler der Pumpe im Heizkreis

Vorlauftemperatur.

Die konventionelle Heizkurve, mit der der Regler die Zielvorlauftemperatur des Heizkreises berechnet, ist in Abbildung 71 dargestellt. Das Verhältnis zwischen der Vorlauftemperatur und der Umgebungstemperatur ist linear. Sinkt die Umgebungstemperatur unter -12°C wird die Zielvorlauftemperatur auf den Maximalwert von 60°C begrenzt. Die minimale Vorlauftemperatur von 20°C wird bei einer Umgebungstemperatur von 17°C erreicht.

Der Regler der Pumpe im Heizkreis ist in Abbildung 72 dargestellt. Dieser Regler vergleicht den Zielwert mit den Istwerten der Raumtemperatur und generiert die Regelungssignale. Der Sollwert der Raumtemperatur ist im Gebäudemodell Variante I (Fußbodenheizung) konstant 21°C . Im Gebäudemodell Varianten II und III ist die Zieltemperatur tagsüber (6-22 Uhr) 21°C und in der Nacht (22-6 Uhr) 17°C .

In Tabelle 14 sind die Parameter der 2 PID-Regler im Heizkreis zusammengefasst.

Tabelle 14: Parameter der PID-Regler im Heizkreis

Parameter	Regler des Mischers	Regler der Pumpe
k	0,1	0,08
T_i (s)	12000	12000
T_d (s)	0,8	1,0

7.2.2 ANN-Regelung

Der in C++ entwickelte ANN-Regelalgorithmus übernimmt bestimmte Regelungsfunktionen des solarthermischen Systems. Durch Training der ANN-Netzwerke „erlernt“ der ANN-Regler das dynamische Wärmeverhalten des Gebäudes und der Heizungsanlage und kann automatisch eine optimale Parametrisierung generieren und das System besser regeln.

Um im Simulationsmodell den ANN-Regelalgorithmus zu implementieren, müssen die ANN-Regelungssignale, die in der C++-Umgebung von dem ANN-Regler generiert werden, mit dem Modell in Dymola verbunden werden. Die Kopplung der C++- und Dymola-Umgebung wird durch eine Co-Simulation mit der FMU/FMI-Technik realisiert. Eine detaillierte Beschreibung dieses Ansatzes beschreibt [10].

Abbildung 73 zeigt die Beziehung und den Informationsfluss zwischen dem Modell in Dymola, der FMU, dem ANN-Netzwerk, dem ANN-Regler und den externen Dateien bei der Simulation des ANN-Regelungsprozesses. Aus Dymola heraus wird das Gebäudemodell und das Modell des Hei-




Abbildung 73: Simulation des ANN-Regelungsprozesses

zungssystems in Form einer FMU (Functional Mock-Up Unit) generiert. Diese FMU beinhaltet alle Informationen und Strukturen des Gebäudemodells und der Heizungsanlage. Diese FMU kann unabhängig von einer Dymolaumgebung zur Simulation genutzt werden. In der Simulation liest der ANN-Regler die benötigten Parameter direkt aus der FMU und gibt die Regelungssignale an die FMU zurück. Die benötigten Wetterdaten lesen der ANN-Regler und die FMU aus externen Dateien.

Die ANN-Netzwerke müssen vor der Simulation trainiert werden. Die Trainingsdaten der Netze werden in Dymola durch Simulation des Modells erzeugt.

7.2.2.1 Training der ANN-Netzwerke

Bevor der ANN-Regler die Regelungssignale generieren kann, müssen die ANN-Netzwerke trainiert werden. Damit die Netzwerke das dynamische Verhalten des in Dymola entwickelten Solar-Kombisystems erlernen können, werden einige wichtige Variablen in der Simulation des Modells alle 60 Sekunden Simulationszeit gespeichert und als Trainingsdaten exportiert. Außerdem werden einige Parameter in den Wetterdaten auch als Trainingsdaten verwendet.

Die für das Trainieren der Netzwerke benötigten Variablen in dem Modell sind:

- Raumtemperatur
- Sollwert der Vorlauftemperatur im Heizkreis
- Zustand des Kessels
- Speichertemperatur in unterschiedlichen Schichten des Speichers
- Außentemperatur
- Solareinstrahlung
- Wolkenbedeckung

Für die ANN-Regelung wurden zwei ANN-Netzwerke trainiert, die für Analyse und Prognose der Raumtemperaturentwicklung bzw. der zukünftigen Speichertemperaturen (Speicherladezustand) zuständig sind.

Die oben genannten benötigten Variablen im System und die Wetterdaten sind die Inputs der ANN-Netzwerke. Beide Netzwerktopologien haben 2 verborgene Schichten. Das Netzwerk für die Raumtemperatur hat 1 Output. Das Netzwerk für die Speichertemperatur hat 5 Outputs. Nach dem Trainieren können die beiden Netzwerke in der Simulation mit den neuen Zustandsgrößen in

Die Werte der Variablen, die die FMU als Outputs an den ANN-Regler exportiert, sind:

- die Raumtemperatur
- die Vorlauftemperatur im Heizkreis
- der Zustand des Kessels (an/aus)
- die Speichertemperaturen in 5 unterschiedlichen Höhen

Die Prognosewerte, die der ANN-Regler berechnet sind:

- die geschätzte zukünftige Raumtemperaturentwicklung
- die geschätzten zukünftigen Speichertemperaturen in 5 unterschiedlichen Höhen des Speichers

Damit generiert der ANN-Regler die notwendigen Regelsignale, welche er an die FMU als Inputs gibt. Diese sind „Einschaltung des Pelletkessels und der Heizkreispumpe“ („0“ aus und „1“ ein) sowie die notwendige Vorlauftemperatur des Heizkreises.

Die Synchronisation des ANN-Reglers und der FMU (Gebäudemodell) erfolgt alle 15 min bezogen auf den simulierten Zeitraum. Das heißt die FMU simuliert das Gebäudeverhalten für 15 min, unterbricht dann die Simulation und übergibt die Werte an den ANN-Regler. Dieser berechnet die Steuersignale für Pelletkessel, Heizkreispumpe und Heizkreisvorlauftemperatur und übergibt diese wieder an die FMU (Gebäudemodell). Mit diesen Steuersignalen wird die dann Simulation wieder für weitere 15 min durchgeführt und das Spiel beginnt von neuem.

Die Simulationsergebnisse, wie z.B. die Wärmeerzeugung des Kessels, die Wärmeverluste in Rohrleitungen, die Raumtemperatur, usw., werden alle 60 Sekunden der Simulationszeit in einer Datei mit der Erweiterung ".dat" gespeichert.

7.3 Simulationsergebnisse

Das Solar-Kombisystem wurde in 3 Varianten mit unterschiedlichen Gebäudedämmstandards (Wärmedämmstandard I, II und III) und unterschiedlichen Wärmeverteilsystemen in folgenden 3 Regelungsmodi simuliert:

- konventionelle Regelung mit konstanter Heizkreisvorlauftemperatur (75°C)
- konventionelle Regelung mit optimierter Heizkurve

- ANN-Regelung

Die Wärmedämmstandards und die Heizsysteme sind in Tabelle 9, Tabelle 10 und Tabelle 12 (S. 124 ff.) beschrieben.

Im ANN-Regelungsmodus wird die Heizkurve des Heizungssystems quasi automatisch generiert. Das ANN-Regelungssystem ermittelt zu jedem Zeitpunkt die optimale Heizkreisvorlauftemperatur unter Berücksichtigung von Außentemperatur, Gebäudeträgheit, zukünftige passive solare Erwärmung und weiterer Effekte. Damit ist eine effizientere Regelung als bei konventioneller Heizkreisregelung möglich.

In der Simulation wird für verschiedene Standorte, Gebäudedämmstandards und Wärmeverteilungssysteme vergleichend jeweils ein konventionelles System mit konstanter Heizkreisvorlauftemperatur (75°C), ein konventionelles System mit optimierter Heizkurve und dem ANN-Regelungsmodus energetisch bewertet. Die Vergleichsbasis stellt das konventionelle System mit konstanter Heizkreisvorlauftemperatur (75°C) dar. In der Realität sind die Heizkurven vieler Heizungssysteme nicht optimal auf die Anforderungen abgestimmt. Der Fall Vorlauftemperatur konstant 75°C stellt hierbei einen Worst-Case Fall dar, die optimale Heizkurve den Idealfall. Reale Heizkurveneinstellungen liegen zwischen diesen beiden Fällen.

7.3.1 Bewertung der Regelungsansätze

Um die Regelansätze zu bewerten und die verschiedenen Regelungsarten zu vergleichen, müssen sowohl die Energiekriterien als auch der Nutzerkomfort des Systems bewertet werden. In diesem Abschnitt werden verschiedene Leistungs- und Komfortindikatoren zur Analyse der Simulationsergebnisse vorgestellt.

Gesamte Wärmeerzeugung des Kessels

Q_{Aux} ist die Wärmemenge, die von einer nicht-solaren Wärmequelle erzeugt wird. Ein energieeffizientes System sollte in der Lage sein, den Verbrauch von nicht-solarer Energie bei gleichen Wetterbedingungen und gleichem Nutzerverhalten zu reduzieren und damit fossile Energie oder andere natürliche Ressourcen einzusparen.

Die Berechnung der Q_{Aux} erfolgt durch einen Integrator im Modell in Dymola. Der Integrator addiert den Wärmebedarf der Zusatzheizung über die gesamte Simulationszeit. Die Ergebnisse werden nach der Simulation exportiert. Monats- und Jahreswerte von Q_{Aux} liegen vor.

Solarer Deckungsanteil

Der solarthermische Deckungsanteil f_{sol} gibt an, wie groß der Anteil des durch Sonnenenergie gedeckten Wärmebedarfs ist. f_{sol} wird als Funktion des Zusatzheizwärmebedarfs und des gesamten Wärmebedarfs für Warmwasserbereitung und Raumheizung nach Gleichung (7.2) berechnet. Monats- und Jahreswerte von f_{sol} sind zu analysieren und bewerten.

$$f_{sol} = \frac{\text{useful solar gains}}{\text{total heat consumption}} = 1 - \frac{Q_{Aux}}{Q_{SH} + Q_{DHW}} \quad (7.2)$$




Abbildung 75: Konventionelle Regelung mit konstanter Vorlauftemperatur

Komfort-Kategorien

Zur Beurteilung des Nutzerkomforts wird die Abweichung von der Raumsolltemperatur bewertet und in 3 Kategorien eingeteilt. Die 3 Kategorien basieren auf der Temperaturdifferenz zwischen der Raumtemperatur T_R und der Zieltemperatur T_{Ziel} (

Tabelle 15). Bewertet wird der zeitliche Anteil mit einer Auflösung von 60s. Wenn die Temperatur in der Kategorie I liegt, ist der Raum behaglich. Auch in der Kategorie II ist die Temperatur relativ angenehm. Liegt die Temperatur in der Kategorie III, ist die Nutzerbehaglichkeit gering.

Während der Heizsaison von Oktober bis März ist die Qualität der Raumtemperaturregelung ausschließlich von der Qualität der Heizungsregelung abhängig. Die passiven solaren Erträge sind geringer als der Heizbedarf der untersuchten Gebäude. In der Übergangszeit und im Sommer werden durch passive solare Erträge zeitweise Temperaturen oberhalb der Solltemperatur erreicht.

Tabelle 15: Komfort-Kategorien

Komfort-Kategorie	I	II	III
$T_R - T_{Ziel}$	$\leq 1K$	$\leq 2K$	$> 2K$
zeitlicher Anteil	a %	b %	x %

Tabelle 16: H_T -Wert und Wärmebedarf des Gebäudes in Varianten I, II und III

Variante Wärmedämmstandard/ Wärmeverteilungssystem	I	II	III
$H_{T,total}$ (W/m ² ·K)	0,33	0,42	1,41
Heizwärmebedarf (kWh/m ² ·a)	47,9	51,3	174,1

Die Ausprägung dieser Überwärmung hängt zum einen natürlich von den passiven solaren Erträgen zum anderen aber insbesondere auch von der thermischen Kapazität der Gebäude und deren Wärmeverluste ab. Für eine objektive Bewertung der Regelungsqualität des Heizungssystems unter den verschiedenen Randbedingungen wurden daher die genannten Komfortkriterien jeweils für den Zeitraum von Oktober bis März bewertet. Aus einem ähnlichen Grunde wurden nur Temperaturen während des Tagbetriebes der Heizung (von 6 bis 22 Uhr) ausgewertet. Häufig wird im Absenkbetrieb die Heizung komplett abgeschaltet. Das Erreichen der Nachtabstempertemperatur hängt dann im Wesentlichen von der thermischen Trägheit des Gebäudes ab und ist daher kein Komfortkriterium des Heizungssystems. Die Regelungssysteme wurden so ausgelegt, dass in diesem Zeitraum möglichst ähnliche Komfort-Kennzahlen generiert wurden.

Wärmeerzeugung und Wärmeverluste

Um die Energieeffizienz des gesamten Systems zu bewerten und die Auswirkungen der verschiedenen Regelungsansätze zu verstehen, werden die Beiträge der einzelnen Wärmequellen (Kessel und Solarkollektor) sowie die Wärmeverluste in den einzelnen Kreisläufen des Gesamtsystems untersucht.

7.3.2 Konventionelle Regelung mit konstanter Heizkreisvorlauftemperatur

Die monatliche Wärmeerzeugung des Kessels und der solare Deckungsgrad des Systemmodells mit konventioneller Regelung mit konstanter Vorlauftemperatur sind in Abbildung 75 dargestellt. Im Winter (von November bis Februar) wird aufgrund der hohen Heizlast sowie der geringen Wärmeerzeugung der Solarkollektoren ein großer Teil der konventionellen Heizwärme verbraucht. In diesen Monaten sind die solarthermischen Deckungsanteile entsprechend gering. Im Sommer (von Mai bis September) ist der Wärmebedarf erwartungsgemäß niedrigerer und die solare Wärmeerzeugung höher. Damit sind die solaren Deckungsanteile auch entsprechend höher.

Die jährlich verbrauchte konventionelle Heizenergie ist in Variante I am niedrigsten und in Variante III am höchsten. Der Hauptgrund dafür ist, dass das Gebäude in Variante I am besten und in Variante III am schlechtesten gedämmt ist. Der H_T -Wert des Gebäudes und der entsprechende Wärmebedarf für Heizung in den Varianten I, II und III sind in Tabelle 16 zusammengefasst.

In den Varianten I und II kann der überwiegende Teil des Wärmebedarfs für Heizung und Warmwasserbereitung im Sommer durch Solarenergie gedeckt werden. Im Sommer, wenn der Wärmebedarf niedrig ist, ist der solare Deckungsgrad immer sehr hoch.

In Variante III ist der Wärmebedarf im Sommer höher und kann nicht vollständig durch Solarenergie gedeckt werden. Der solare Deckungsgrad wird im Sommer starker von den Witterungsbedingungen (Solareinstrahlung, Bewölkung, usw.) beeinflusst.

Im Vergleich zu Variante I und II ist der gesamte Wärmeverlust in den Rohrleitungen im Kesselkreis größer; der gesamte Wärmeverlust in den Rohrleitungen im Solarkreis und der Wärmeverlust des Speichers sind geringer. Der Grund dafür kann sein, dass in Variante III mehr konventionelle Energie verbraucht wird, weniger solare Energie erzeugt wird und weniger Wärmemenge im Speicher gespeichert wird.




Abbildung 76: Simulationsergebnisse – konventionelle Regelung mit optimierter Heizkurve

7.3.3 Konventionelle Regelung mit optimierter Heizkurve

Die monatliche Wärmeerzeugung des Kessels und der solare Deckungsgrad des Systemmodells mit konventioneller Regelung mit optimierter Heizkurve sind in Abbildung 76 dargestellt.

Das dynamische Verhalten der beiden konventionellen Regelungen (mit konstanter Vorlauftemperatur, Abschnitt 7.3.2 und mit optimierter Heizkurve) ist ähnlich.

7.3.4 ANN-Regelung

Die monatliche Wärmeerzeugung des Kessels und der solare Deckungsgrad des Systemmodells mit ANN-Regelung sind in Abbildung 77 dargestellt. Der Wärmebedarf des Gebäudes kann in den Varianten I und II in Juli, August und September vollständig durch Solarenergie gedeckt werden. Die Jahresverläufe unterscheiden sich nicht grundsätzlich von denen mit konventioneller Regelung




Abbildung 77: Simulationsergebnisse – ANN Regelung






Abbildung 78: Monatswerte von Q_{Aux} und f_{sol} für die 3 Varianten

7.3.5 Vergleich der drei Regelungsmodi

7.3.5.1 Fossiler Nachheizbedarf und Solarer Deckungsgrad

Die Monatswerte des konventionellen Wärmeverbrauchs Q_{Aux} und der solaren Deckungsanteile f_{sol} der 3 Varianten sind in Abbildung 78 dargestellt. Fast durchgängig benötigt der ANN-Regelungsansatz die geringste konventionelle Nachheizung.

Bemerkenswert ist, dass bei Variante II im Januar die ANN Regelung einen höheren Bedarf an fossiler Nachheizung hat als die beiden anderen Varianten. Eine genauere Analyse zeigt, dass wegen der geringen Außentemperaturen die verfügbare Heizleistung in allen Fällen nur wenig über der Leistung liegt, die notwendig ist, um das Gebäude dauerhaft auf der gewünschten Raumtemperatur zu halten. Folge davon ist, dass die Solltemperatur bei Abweichung nur sehr langsam erreicht wird. Die ANN Regelung beginnt aufgrund der Prognosefähigkeit in diesem Fall sehr viel früher als die anderen Varianten mit einer Anhebung der Heizkreisvorlauftemperatur. Bei den konventionellen Regelungen ergibt sich damit häufiger eine unzureichende Raumtemperatur. In dieser Situation entsteht bei den konventionellen Regelungen zwar ein geringerer fossiler Nachheizbedarf, der gleichzeitig ab auch mit einem starken unzulässiges Absinken des Komforts verbunden ist.




Abbildung 79: Jahreswerte von Q_{Aux} und f_{sol} für die 3 Varianten




Abbildung 80: Jahreswerte von Q_{Aux} relativ zur Regelung mit konstanter Vorlauf­temperatur für die 3 Varianten

Der jährliche konventionelle Energieverbrauch ist in den Systemen mit der ANN-Regelung in allen 3 Varianten am geringsten (Abbildung 79). Die Prognosefähigkeit des ANN-Regelungsansatzes ermöglicht sowohl absolut (Abbildung 79) als auch relativ (Abbildung 80) die höchste Energieeinsparung in Variante III (Dämmstandard entsprechend dem Gebäudebestand in Deutschland aus den 1950 Jahren). Damit ist der ANN-Regelungsansatz ein prädestinierter Weg, den Energieverbrauch insbesondere im Gebäudebestand signifikant zu reduzieren.

Der jährliche solare Deckungsgrad der ANN-Regelung ist in allen Varianten höher als der der konventionellen Regelungen. Vergleich mit Abbildung 77 zeigt, dass vor allem in der Übergangszeit April, Mai und September die ANN-Regelung den größten Vorteil generiert. In dieser Zeit ist das Angebot an solarer Strahlung bereits hoch, gleichzeitig besteht auch noch signifikanter Heizbedarf: Eine optimale Speicherbewirtschaftung ist daher in diesem Zeitraum besonders wirksam.

Die relative Betrachtung (Abbildung 80) zeigt, dass die Optimierung einer konventionellen Heizkreisregelung mit konstanter Vorlauf­temperatur durch eine optimale Heizkurve in den betrachteten Fällen ca. 2-5% Einsparung an fossiler Heizenergie einspart. Der ANN Regelungsansatz kann bis zu 12% einsparen.

7.3.5.2 Nutzerkomfort

Die Bewertung der Komfort-Kriterien für alle untersuchten Varianten ist in Abbildung 81 dargestellt. Wie bereits weiter oben beschrieben, wurden die Systeme so abgestimmt, dass in etwa gleiche Komfortkennzahlen entstehen. Damit sind faire Vergleiche des Energieverbrauchs möglich.

Variante III (schlecht gedämmtes Gebäude) zeigt allerdings signifikant höheren Komfort. Dies ist Folge des anderen Verhältnisses von Heizleistung zu Wärmekapazität des Gebäudes. Der wesentlich geringere Dämmstandard des Gebäudes erfordert signifikant höhere Heizleistung, bei gleichzeitig fast unveränderter Wärmekapazität des Gebäudes. Dadurch kann ein Temperaturanstieg nach Nachtabsenkung wesentlich schneller erfolgen und die gewünschte Zieltemperatur schneller erreicht werden.

Alle Regelungsansätze weisen Abweichung von mehr als 2 K in einem akkumulierten Zeitraum von weniger als 6% des betrachteten Zeitraums auf, wobei die Heizungsregelung mit optimierte Heizkurve eine bessere Komfortkennzahl als die Regelung mit konstanter Vorlauftemperatur erreicht und die ANN-Regelung den höchsten Komfortwert erzielt.

Damit zeigt sich, dass insbesondere der ANN-Regelungsansatz signifikant höhere Energieeffizienz bei gleichzeitiger Komfortsteigerung ermöglicht.






Abbildung 81: Komfort-Kategorien der drei Regelungsarten in den Varianten I, II und III

7.3.5.3 Wärmeerzeugung und Wärmeverluste

Wärmequellen sind der Kessel und die Solarkollektoren. Da die Temperaturen der Arbeitsmedien im Kesselkreis und im Solarkreis häufig hoch sind, wurden im Systemmodell in diesen beiden Kreisen Wärmeverluste durch Rohleitungen berücksichtigt. Die Wärmeverluste der Rohleitungen im Heizkreis und Trinkwarmwasserkreis wurden vernachlässigt. Wärmeverluste am Speicher wurden ebenfalls berücksichtigt.

Die Wärmeerzeugungen des Kessels und der Solarkollektoren sind in Abbildung 82 dargestellt. Die insgesamt erzeugte Wärmemenge, welche dem Wärmebedarf zuzüglich der Wärmeverluste entspricht, sinkt durch den Einsatz von optimierten Systemen (optimierte Heizkurve bzw. ANN) in allen Varianten. Dadurch sinkt auch der Bedarf an fossiler Nachheizung (Kessel). Bemerkenswert ist aber, dass die solare Wärmeerzeugung nicht in gleichem Masse abnimmt. Der solare Anteil der Wärmeerzeugung nimmt zu, im Fall der Fußbodenheizung mit gut gedämmten Gebäude in der Kombination mit ANN (Variante I ANN) nimmt sogar der absolute Betrag der solaren Wärmeerzeugung zu.




Abbildung 82: Wärmeerzeugungen durch Kessel und Solarkollektor

Abbildung 83 zeigt die Wärmeverluste des Speichers sowie der Rohrleitungen des Solarkreises und des Kesselkreises. Wegen geringerer fossiler Nachheizbedarfe bei den optimierten Systemen (opt. HK und ANN), sind die Laufzeiten des Kessels reduziert und damit auch die Wärmeverluste der Rohrleitungen des Kesselkreises. Die Verluste des Solarkreises sind innerhalb der jeweiligen Variante jeweils sehr ähnlich. Jedoch fällt auf, dass bei Variante II und III die Verluste des Solarkreises bei ANN-Regelung etwas höher sind als bei den anderen Regelungen. Noch wesentlich ausgeprägter ist dieses Verhalten bei den Speicherverlusten zu beobachten. Zu erklären ist beides damit, dass das ANN-System häufig höhere Vorlauftemperaturen des Heizkreises generiert, um schneller die gewünschte Raumtemperatur zu erreichen. Dies führt zu besseren Komfortkennzahlen (vgl. Abbildung 81) als bei den konventionell geregelten Systemen. Andererseits führt dies auch zu zeitweise höheren Speichertemperaturen, welche die dargestellten erhöhten Speicherverluste bedingen. Bezogen auf den gesamten Wärmebedarf des Gebäudes beläuft sich dieser erhöhte Verlust im Speicher auf etwa 1%. Dieser Wert kann reduziert werden, wenn die Komfort-




Abbildung 83: Wärmeverluste im System

anforderungen soweit abgesenkt werden wie bei den konventionellen Regelungen. Entsprechende Optimierungsschritte sind in einer zukünftigen Weiterentwicklung des Ansatzes zu berücksichtigen.

An dieser Stelle sei nochmals darauf hingewiesen, dass der ANN-Ansatz gleichzeitig eine Komfortsteigerung und trotz der damit verbundenen erhöhten Wärmeverluste im Speicher und im Solarkreis eine signifikante Reduzierung des fossilen Nachheizbedarfs ermöglicht.

7.4 Ergebnisse Energetische Bewertung

Die Energetische Bewertung des ANN-Regelungsansatzes zeigt, dass Einsparungen von fossiler Energie in Höhe von bis zu 12% gegenüber dem aktuellen Stand der in Betrieb befindlichen Regelungen möglich sind. Diese Ergebnisse wurden aufgrund von Simulationen am Standort Freiburg im Breisgau generiert. Simulationsergebnisse für den Standort Potsdam, welche in diesem Bericht nicht dargestellt wurden, bestätigen die Größenordnung dieser Ergebnisse. Die höchsten relativen und auch absoluten Einsparungen können im Gebäudebestand erzielt werden. Der Gewinn im Neubau fällt geringer aus.

Der ANN-Ansatz ist darüber hinaus geeignet den Nutzerkomfort zu erhöhen. Dies heißt, dass die gewünschte Raumtemperatur besser eingehalten werden kann als bei herkömmlichen Regelungssystemen und dies bei gleichzeitiger Einsparung fossiler Energie.

8 Kosten- /Nutzenanalyse

Die im Rahmen des Projektes ANNsolar entwickelte Methode der Neuronalen Netze für die Regelung von solarthermischen Kombianlagen ist bezüglich der Kosten und Aufwände zu bewerten. Ziel ist dabei, die Aspekte Anwender/Installateur, Hardware und Programmierung zu beleuchten. Die Ergebnisse dieser Bewertung dienen dazu, insbesondere unter wirtschaftlichen Gesichtspunkten die Zukunftsaussichten einer solchen Technologie zu ermitteln.

Die Arbeiten im Projekt ANNsolar wurden von den Industriepartnern Prozeda, Sorel und Steca begleitet. Im Rahmen von mehreren Projekttreffen sind Ergebnisse vorgestellt und diskutiert worden. Die Industriepartner waren aufgefordert eine kritische Bewertung der möglichen Aussichten der Neuronalen Netzwerke durchzuführen.

Ergebnisse dieser Bewertung und mögliche Konsequenzen werden im Nachfolgenden dargestellt. Die Frage der eigentlichen technischen Machbarkeit einer ANN-Regelung steht dabei nicht im Vordergrund, diese wird im Folgenden vorausgesetzt. Ziel ist, wesentliche Konsequenzen des komplett neuen Ansatzes zu bewerten.

8.1 Mögliche Nachteile eines ANN-Regelungsansatzes

Die Erwartung der Industriepartner ist, dass ANN-Algorithmen nicht alle bisherigen Funktionen der Regelung übernehmen können. Dies gilt insbesondere für die Abdeckung von sicherheitsrelevanten Funktionen, wo einfache und klare kausale Zusammenhänge bestehen, sowie bei der Fehlererkennung in der Anlage.

Darüber hinaus besteht die Befürchtung, dass erhebliche Schwierigkeiten bei Qualitätstests und Kundensupport entstehen könnten. Eine feste Nachvollziehbarkeit der Regelungsfunktion ist nicht gegeben. Bei der ANN-Regelung handelt es sich zumindest teilweise um eine Black Box. Vermeintliche oder tatsächlich fehlerhafte Regelungen (Software- oder Hardwarefehler) können kaum durch Logik nachvollzogen werden. Wesentliche Anforderung ist daher ein schlüssiges und effizientes Konzept für Tests in der Fertigung als auch im Kundensupport. Eine optionale Umschaltung auf konventionelle Regelung könnte ebenfalls helfen, Schwierigkeiten zu reduzieren.

Als Konsequenz der Erkenntnisse aus der Projektarbeit sowie der kritischen Diskussion mit den Industriepartnern wurde das Regelungskonzept im Laufe des Projektes in oben genannter Hinsicht geändert. Diese Änderung ist vor allem durch die Tatsache der kaum möglichen logischen Nach-

vollziehbarkeit von Aktivitäten der Regelung begründet. Entsprechend werden ANN-Strukturen nur auf niedriger Ebene der Regelungslogik angewendet. Konkret heißt dies: ANN-Strukturen werden genutzt, um die Raumtemperatur und den Zustand des thermischen Speichers zu prognostizieren sowie implizit eine Korrelation zwischen Wetterprognosedaten und lokal auftretenden Umgebungstemperaturen, Erträgen der Solaranlage sowie passiven solaren Gewinnen des Gebäudes herzustellen. Dadurch verbleibt eine noch vertretbare Transparenz und ausreichende Nachvollziehbarkeit der Aktivitäten der Regelung, welche das mögliche K.O.-Kriterium in Bezug auf Qualitätssicherungstest und Kundensupport entkräften.

Die Programmierung Neuronaler Netzwerke erhöht zunächst die Anforderungen an die Entwickler, die entsprechende Projekte umsetzen müssen. Kenntnisse über Neuronale Netze sind bei Entwicklern und Programmierern im Allgemeinen nicht gegeben. Zusätzlicher Aufwand für die Weiterbildung des Entwicklungspersonals ist nötig. Ob tatsächlich reduzierte Aufwände bei der Programmierung entstehen, wird in Frage gestellt.

Gegenüber herkömmlichen Ansätzen benötigt die Regelung mit Neuronalen Netzen möglicherweise deutlich mehr Ressourcen, bezogen auf die ausführende Hardware. Speziell Rechenleistung und der Bedarf an Speicher für das Training der ANN verlangen leistungsfähige Rechnerhardware. Sofern diese Leistungsfähigkeit durch den eigentlichen Regler zur Verfügung gestellt werden müsste, wäre das je nach existierender Hardware mit höheren Stückkosten für die Elektronik verbunden. Dem stehen die Einsparungen im Entwicklungsbereich bei breiter Einführung dieser Regelungslogik gegenüber.

Die bisherigen Ergebnisse der Arbeiten zeigen, dass im eigentlichen Regelbetrieb die Anforderungen an die Reglerhardware nicht wesentlich von den heutigen Anforderungen abweichen. Richtig ist zwar, dass für das Training der ANN signifikant höhere Anforderungen bestehen. Je nach Hersteller können solche höhere Anforderungen aber zum einen mit bereits existierender Hardware ohne großen Mehraufwand abgedeckt werden, zum anderen besteht auch die Möglichkeit, das Training in die Nachtstunden zu verlegen, in denen der Regler weniger stark durch eigentliche Regelungsaufgaben beansprucht wird. Ein anderer Ansatz besteht darin, für dieses Training externe Ressourcen in Anspruch zu nehmen, welche bei zunehmender IT-Vernetzung nicht lokal zur Verfügung gestellt werden müssten.

Ein Hersteller beziffert mögliche Mehrkosten der Hardware auf schätzungsweise 25% der aktuellen Produktionskosten. Ein Neuaufsetzen von Hard- und Software würde idealerweise auf Basis von preisgünstigen verfügbaren und sehr leistungsstarken Micro-PC Lösungen wie z.B. Arduino-, Raspberry- oder Embedded Linux Lösungen erfolgend. Ein Neuaufsetzen der Software würde nach Schätzung des ISE Kosten im Bereich von 50000-100000 EUR erzeugen.

Als weitere Schwierigkeit wird von den Industriepartnern aufgeführt, dass die Umsetzung einer Regelaufgabe mit einer „neuen“ Technik möglicherweise viel Überzeugungsarbeit beim Kunden erfordert. Dies gilt insbesondere für teilweise technisch und/oder mathematisch weniger gebildeten Kunden.

8.2 Vorteile eines ANN-Regelungsansatzes

Die Industriepartner sehen einen wesentlichen Vorteil bei der Anwendung Neuronaler Netze in der Regelungstechnik durch die Verwendung eines einzigen ANN-Prognosekerns für unterschiedliche Regelungsaufgaben. Möglich ist damit eine einheitliche Struktur von Softwarelösungen für unterschiedliche Geräte bzw. Reglerserien.

Die ANN-Prognose wird nicht durch die Softwarestruktur, sondern durch die Trainingsdaten bestimmt. Soll das Regelungsverhalten geändert werden, muss keine Änderung der Software erfolgen. Es wird lediglich der Trainingsdatensatz ausgetauscht. Damit sind mögliche Softwarefehler bei der Anpassung ausgeschlossen. Die Simulation und Optimierung von Datensätzen kann ggfs. vorab auf leistungsfähigen PCs durchgeführt werden und damit die Qualität der Regelung bewertet werden, ohne Feldtests durchführen zu müssen.

Wegen der in 8.1 begründeten Änderung des Regelungskonzeptes wird dieser Vorteil allerdings zu Gunsten einer einfacheren Qualitätssicherung und eines weniger aufwändigen Kundensupports nur in geringem Umfang auftreten.

Die Industriepartner sehen einen hohen Energieeffizienznutzen des ANN-Regelungsansatzes durch die kontinuierliche Selbstoptimierung der Regelung. Die Praxis zeigt, dass bei vielen Anlagen eine Optimierung während der Inbetriebnahme ausbleibt. Verantwortlich dafür sind fehlende Bereitschaft des installierenden Personals oder mangelndes Wissen über die notwendigen Maßnahmen. Die hohe Auslastung der Installateure sowie der Mangel an gut ausgebildetem Personal werden als Gründe genannt. Mögliche und notwendige Einstellungen und Optimierungsmöglichkeiten werden daher oft nicht genutzt. Folge davon ist eine Vielzahl von Anlagen, die schlecht und wenig energieeffizient arbeiten. Hier kann der Ansatz des ANN-Projektes gleichzeitig zu deutlichen Energieeinsparungen und einem höheren Nutzerkomfort führen. Die Untersuchung der energetischen Effekte des ANN Regelungsansatzes zeigen, dass unter deutschen Randbedingungen energetische Einsparpotenziale von 12% und ggfs. mehr realisiert werden können bei gleichzeitiger Erhöhung des Nutzerkomforts (vgl. Abschnitt 7).

Ebenso kann damit die Anpassung an Änderungen im Umfeld der Regelung entfallen, die im laufenden Betrieb durchaus problematisch sind, da nur wenige Anlagen laufend auf Energieeffizienz geprüft werden. Darunter fallen Veränderungen in der Hydraulik wie z.B. Verkalkung oder sich

über die Laufzeit verändernde Pumpenkennlinien ebenso wie bauliche Veränderung z.B. an der Gebäudehülle oder Installation von neuen Heizkörpern oder eines Kaminofens.

Durch die Eigenschaften der neuronalen Regelung ist eine Verringerung der nötigen Einstellparameter möglich. Weniger Parameter ergeben eine schnellere und sicherere Installation sowie eine einfachere Bedienung beim Endanwender. Weniger Parameter bedeuten letztendlich auch weniger Möglichkeiten, Fehler zu begehen. Dies wird die Installations- und Betriebssicherheit der Anlagen erhöhen, zu Zeitersparnis bei der Installation beitragen und durch nicht nötige Nacharbeits- und Optimierungsbesuche zu monetären Einsparungen führen.

Mögliche Einsparungen hier sind aber auch bei der Erstellung von Unterlagen für Dokumentation und Bedienung des Gerätes möglich. Die Schulung von Personal wird ggfs. vereinfacht und kann damit zu Kosteneinsparungen führen.

Nicht zuletzt im Bereich des Marketings können oben genannte Punkte Vorteile gegenüber den konventionellen Lösungen der Konkurrenz bringen. Gelingt die Überzeugungsarbeit, stehen hier starke Vertriebsargumente zur Verfügung.

8.3 Ergebnisse der Kosten- /Nutzenanalyse

Die Bewertung der Kosten- und Nutzen des entwickelten ANN-Regelungsansatzes zeigt, dass bei der Entwicklung und Umsetzung neuer Regler Aufwände für Programmierung voraussichtlich nicht wesentlich anders sein werden als bei heutigen Regelungsansätzen. Hardwarekosten werden voraussichtlich maximal 25% höher liegen als bei einfachen Reglern für Solaranlagen. Sofern Neuentwicklungen von Reglern (Hardware- und Software) notwendig sind, werden schätzungsweise Einmalkosten in der Größenordnung von 50000-100000 EUR entstehen, wie dies auch bei konventionellen neuen Reglerentwicklungen notwendig wäre.

Der ANN-Ansatz verspricht aber signifikante Steigerungen der Energieeffizienz. Ein bis zu 12% geringerer fossiler Energiebedarf bei Einsatz des ANN-Regelungsalgorithmus im deutschen Gebäudebestand wurde durch Simulation in einem solarthermischen Kombisystem nachgewiesen. Hiermit steht eine sehr kostengünstige Lösung bereit, signifikante Energieeffizienzsteigerungen in großem Maßstab insbesondere im Gebäudebestand mutmaßlich weit über solarthermische Anwendungen hinaus zu ermöglichen.

Leider ist von Seiten der Industriefirmen kaum zu erwarten, dass unter den aktuellen schwierigen Marktbedingungen Investitionen in neue solarthermische Produkte getätigt werden. Der Markt für solarthermische Regler ist in den vergangenen Jahren stark zurückgegangen.

Ermutigend ist aber, dass am Projekt beteiligte Reglerhersteller sowie weitere Reglerhersteller und Anwender großes Interesse an der Fortsetzung der Entwicklung des ANN-Ansatzes zeigen. Notwendig ist dabei aber eine Öffnung des Ansatzes für weitere Wärmeerzeuger und Systeme über die Solarthermie hinaus.

9 Zusammenfassung und Ausblick

Künstliche Neuronale Netze sind, wie das menschliche Gehirn, in der Lage, Handlungsstrategien selbstständig anhand von „erlebten“ Beispielen (i.e. Trainingsdaten) zu entwickeln. Der Aufbau eines künstlichen neuronalen Netzes orientiert sich dabei an den Erkenntnissen der Biologie über die Funktionsweise des menschlichen Gehirns. Es liegt nahe, solche Netze auch für technische Regelungen einzusetzen. Für solarthermischer Heizungssysteme kann ein solches künstliches neuronales Netz genutzt werden, um die individuelle thermische Dynamik des Gebäudes und die Auswirkung von passiver und direkter Solarstrahlung auf dessen Wärmebedarf zu erfassen und den Ladezustand des Speichers in Abhängigkeit der Betriebsbedingungen zu prognostizieren. Hierfür ist keine Simulation erforderlich. Das neuronale Netz ist selbstständig in der Lage, die entsprechenden Abhängigkeiten zu erlernen. Im vorliegenden Projekt wurde untersucht, wie ein solcher ANN Ansatz nutzbringend für die Regelung solarthermischer Heizungsanlagen eingesetzt werden kann. Neben der technischen Umsetzung wurden vor allem auch Aspekte der möglichen Steigerung der Energieeffizienz und möglicher Aufwandsreduzierungen bei Herstellung und Qualitätssicherung beim Hersteller sowie Inbetriebnahme am Objekt untersucht.

ANN-Algorithmen können, individuelle Randbedingungen wie lokales Klima, thermodynamisches Verhalten eines Gebäudes sowie charakteristisches Betriebsverhalten der solarthermischen Anlage und des Wärmeverteilsystems selbstständig identifizieren. Im Regelungsbetrieb kann dann die Entwicklung der Raumtemperatur und des Speicherladezustandes prognostiziert werden, um damit optimalen Betrieb zu ermöglichen. Neben der Maximierung von Solarertrag und Energieeffizienz ist durch diesen Ansatz auch eine Reduzierung der Kosten bei Installation und Inbetriebnahme der Regler möglich. Die Kombination von künstlichen neuronalen Netzen (Artificial Neural Network (ANN)) und einer Linearen System Identifikation (LSI) zur Analyse des nichtlinearen und linearen Teils des dynamischen Verhaltens der Anlage und des Gebäudes erlaubt eine robuste KI-Lösung für Heizungsregelungen. Die benötigten Algorithmen für diesen Ansatz wurden am Fraunhofer ISE entwickelt und in einen Regelungscode implementiert.

Die Prognosen von Raumtemperatur und Speicherladezustand stellen die wesentliche Basis des entwickelten Regelungskonzeptes dar. Die genannten Größen können mit Hilfe der Kombination aus ANN und LSI in guter Genauigkeit prognostiziert werden. Für die Überprüfung dieser Aussage wurden Messdaten einer real existierenden Anlage genutzt, um ANN Netze zu trainieren. Die trainierten ANN Netze konnten folgende Genauigkeiten (jeweils für das 80% Quantil) erzielen:

Raumtemperatur $\pm 0,5$ K, Speicherladezustand ± 10 K. Nochmals zu betonen ist, dass all diese Prognoseergebnisse ohne Simulation erreicht werden. Dieser Ansatz stellt daher ein hervorragendes Instrument zur schnellen und kostengünstigen Prognose dar.

Basierend auf dieser ANN-Prognosefunktion wurde ein ANN-Regelungsansatz entwickelt. Die ANN-Regelung übernimmt folgende Regelungsfunktionen: 1. Sollwertermittlung der Vorlauftemperatur des Heizkreises 2. Regelung der Zuschaltung der fossilen Nachheizung. Die übrigen Funktionen entsprechen im Wesentlichen denen einer konventionellen Regelung. Bei der Ermittlung des Sollwertes der Heizungsvorlauftemperatur wird dieser Wert solange variiert, bis die prognostizierte Raumtemperatur der gewünschten entspricht. Dieser Ansatz entspricht einer automatischen Heizkurvenermittlung, welcher zusätzliche Einflüsse wie z.B. passive solare Erwärmung des Gebäudes berücksichtigt. Für die Entscheidung über die Einschaltung der fossilen Nachheizung wird überprüft, ob die notwendigen Speichertemperaturen innerhalb eines Prognosezeitraums erreicht sein werden. Unnötige Brennerstarts unterbleiben und solarer Ertrag wird maximiert.

Die Anforderungen des entwickelten Regelungsalgorithmus an die Hardware im Regelungsbetrieb unterscheiden sich nicht wesentlich von denen konventioneller Regelungsalgorithmen. Höhere Anforderungen entstehen jedoch durch das für die Regelung notwendige Training. Marktgängige Regelungshardware aus dem oberen Leistungssegment aktueller Heizungsanlagen erfüllen aber schon heute auch diese Anforderungen. Durch die zunehmende Digitalisierung sind auch Cloud-Lösungen für die Trainingsaufgabe nutzbar. Damit stellt die Hardware keine wesentliche Hürde für den Einsatz von ANN Regelungsansätzen dar.

Beim entwickelten ANN-Regelungsansatz werden einzelne Funktionen einer konventionellen Regelung durch einen neuen Ansatz ersetzt. Die bestehende Softwarestruktur kann dabei grundsätzlich bestehen bleiben. Aufwände für die Implementierung sind daher in ähnlicher Größenordnung zu erwarten wie beim Neuanlegen einzelner Funktionsblöcke in einer Regelungssoftware.

In einem Gebäude wurde die Funktionsfähigkeit des Regelungsansatzes unter realen Randbedingungen nachgewiesen. Das wesentlich dynamischere Verhalten der Regelung erlaubt schnelleres Aufheizen auf Solltemperatur zum Beispiel nach Nachtabsenkung, besseres Halten der Zieltemperatur durch Berücksichtigung von Wettervorhersagedaten und effizienteres Heizen bei Wärmeeintrag durch weitere Wärmequellen wie passive solare Erwärmung oder Kaminofenbetrieb.

Bisherige Simulationsergebnisse zeigen, dass durch die Nutzung des KI-Ansatzes Energieeinsparungen bis zu 12% möglich sind. Die höchsten relativen und absoluten Steigerungen der Energieeffizienz werden bei Gebäuden mit geringerem Wärmedämmstandard erzielt, also bei Gebäuden wie sie heute überwiegend im Gebäudebestand existieren. Damit stellt der ANN-Regelungsansatz, der auch für Heizungssysteme ohne solarthermische Unterstützung eingesetzt werden kann, eine

kostengünstigen und effizienten Maßnahme für die Erreichung der Klimaziele dar. Wichtig ist an dieser Stelle nochmals zu betonen, dass die Inbetriebnahmen und der Betrieb der Anlage mit dem entwickelten Regelungsansatz einfacher ist als bei einer konventionellen Anlage, weil weniger Parameter eingestellt werden müssen.

Die Simulation zeigt darüber hinaus, dass neben der Steigerung der Energieeffizienz gleichzeitig eine Verbesserung des Nutzerkomforts eintritt. Die Einhaltung der Zieltemperatur im Gebäude gelingt dem ANN-Ansatz besser als einer herkömmlichen Regelung, da die ANN-Regelung nicht nur aktuelle Daten sondern auch prognostizierte zukünftige Werte berücksichtigt.

Künstliche neuronale Netze bieten daher eine hervorragende Möglichkeit, Heizungsanlagen effizienter und kostengünstiger zu regeln. Einhergehend mit signifikanten Energieeinsparungen insbesondere im Gebäudebestand können mit einem ANN Ansatz Verbesserungen des Nutzerkomforts erreicht werden. Der ANN-Regelungsansatz kann damit einen wirkungsvollen und kostengünstigen Beitrag zur Erreichung der Klimaziele leisten.

10 Literaturverzeichnis

- [1] D. Kriesel, „Ein kleiner Überblick über Neuronale Netze,“ 2011. [Online]. Available: <http://www.dkriesel.com>. [Zugriff am 14 August 2015].
- [2] S. Haykin, Neural Networks – A Comprehensive foundation, 2nd Hrsg., Upper Saddle River, NJ: Prentice Hall, 2005.
- [3] Wikipedia, „Hauptkomponentenanalyse,“ 7 Juli 2015. [Online]. Available: <https://de.wikipedia.org/w/index.php?title=Hauptkomponentenanalyse&oldid=143815750>. [Zugriff am 17 August 2015].
- [4] H. Khalil, Nonlinear Systems, 2nd Hrsg., Upper Saddle River, NJ: Prentice Hall, 1996.
- [5] C. Chen, Linear system theory and design, Oxford: Oxford University Press, 1999.
- [6] D. O. Hebb, The Organization of Behavior: A Neuropsychological Theory, New York: Wiley, 1949.
- [7] Fraunhofer ISE, Institute for Solar Energy Systems Library (ISELib), „Internal Modelica Library v2.0.0,“ Freiburg, Germany, 2016.
- [8] B. Lab, „Modelica Buildings Library v3.0.0, 2016,“ 2016. [Online]. Available: <http://simulationresearch.lbl.gov/modelica/releases/v3.0.0/help/Buildings.htm>. [Zugriff am 10 Juli 2018].
- [9] U. Jordan und K. Vajen, „DHWcalc Tool for the Generation of Domestic Hot Water (DHW) Profiles on a Statistical Basis,“ University of Kassel, Department of Solar and System Engineering, Kassel, 2003.
- [10] Modelica Association, „Modelica Association Project "FMI" (2014): Functional Mock-up Interface for Model Exchange and Co-Simulation 2.0,“ 2016. [Online]. Available: <https://svn.modelica.org/fmi/branches/public/specifications/v2.0/>

FMI_for_ModelExchange_and_CoSimulation_v2.0.pdf. [Zugriff am 11 Juli 2016].

- [11] „fmi-standard.org,“ [Online]. Available: https://svn.modelica.org/fmi/branches/public/specifications/v2.0/FMI_for_ModelExchange_and_CoSimulation_v2.0.zip.
- [12] C. Rhode, „An Introduction to Neural Networks: The Perceptron,“ [Online]. Available: www.lowercolumbia.edu/students/academics/facultyPages/rhode-cary/intro-neural-net.htm. [Zugriff am 14 August 2015].
- [13] T. Neidhold und T. Blochwitz, „FMI: Functional Mockup Interface for Model Exchange and Co-Simulation,“ 2013. [Online]. Available: www.itisim.com.
- [14] Modelon AB, „FMI Library,“ 2016. [Online]. Available: http://www.jmodelica.org/api-docs/FMIL_docs/FMILibrary-2.0.2b3.pdf. [Zugriff am 2016 Juli].
- [15] Wikipedia, „V-Modell,“ 2016. [Online]. Available: <https://de.wikipedia.org/w/index.php?title=V-Modell&oldid=150860238>. [Zugriff am 1 August 2016].

11 Tabellenverzeichnis

Tabelle 1: Funktionalitäten und Merkmale der ANN-Software	42
Tabelle 2: Parameter des Ausgabemoduls	57
Tabelle 3: Beispiel und Format der Vorgabe von Raumtemperatur und Trinkwassertemperatur durch den Nutzer	58
Tabelle 4: Anteil von LSI und ANN am Output bei dem vollständig trainierten Speichertemperaturnetz.	81
Tabelle 5: Anteil von LSI und ANN am Output bei dem kurz trainierten Speichertemperaturnetz.	82
Tabelle 6: Anteil von LSI und ANN am Output bei untrainiertem Speichertemperaturnetz.	83
Tabelle 7: Anteil von LSI und ANN am Output des Raumtemperaturnetzes im Trainingsverlauf...	84

Tabelle 8: Vergleich der 90 %-Quantile von unterschiedlichen Trainingszeiträumen.....	114
Tabelle 9: U-Werte der Elemente der Gebäudehülle im Gebäudemodell.....	124
Tabelle 10: Berechnete Normheizlast des Gebäudes für die untersuchten Varianten	127
Tabelle 11: Parameter der Solarkollektor-Komponente	130
Tabelle 12: Heizungs-systeme im Gebäudemodell.....	134
Tabelle 13: Parameter des PID-Reglers im Trinkwarmwasserkreis.....	138
Tabelle 14: Parameter der PID-Regler im Heizkreis	139
Tabelle 15: Komfort-Kategorien.....	146
Tabelle 16: HT-Wert und Wärmebedarf des Gebäudes in Varianten I, II und III	147

12 Abbildungsverzeichnis

Abbildung 1: Neuronales Netzwerk des menschlichen Gehirns (aus [12]).....	11
Abbildung 2: Mathematisches Modell eines Neurons.....	12
Abbildung 3: Beispiel eines technischen neuronalen Netzes	12
Abbildung 4: Schematischer Vergleich zwischen Feed-forward und Recurrent Topologie	13
Abbildung 5: vollständig verbundene Topologie, bei der alle Neuronen der ersten verdeckten Schicht miteinander verknüpft sind.	14
Abbildung 6: Modellierung eines dynamischen Systems mit einer Recurrent-Topologie bestehend aus einem Feed-forward Kern und einer zeitlich verzögerte Rückkopplung.....	16
Abbildung 8: Einfache Feed-Forward Struktur mit einer Eingabeschicht, einer verdeckten Schicht und einer Ausgabeschicht.....	20
Abbildung 9: lokale Minima, globales Minimum und Gradienten. Der Index 0 bzw.1 benennt hier die Anzahl der Iterationsschritte.....	22

Abbildung 10: Implementierung einer Hauptkomponentenanalyse mit Hilfe eines neuronalen Netzwerkes..... 26

Abbildung 11: Referenz-Solaranlage für die kombinierte Heizung und Warmwassererzeugung mit Kollektor, Wärmetauscher für die Warmwasserbereiter konventionellem Wärmeerzeuger und Wärmespeicher 28

Abbildung 12: Kreisläufe der hydraulischen Anlage 35

Abbildung 13: Hauptmodule von WinANN auf dem obersten Programmlevel..... 43

Abbildung 14: Struktur der Systeme der ANN Software mit Kalibrator, Trainer und ANN Kern ... 44

Abbildung 15: Excel-Datensatz zur Verarbeitung mit WinANN 45

Abbildung 16: Konfiguration des ANNSystem-Moduls 46

Abbildung 17: Ergebnis der Hauptachsenanalyse..... 47

Abbildung 18: Konfiguration der Netzwerktopologie..... 47

Abbildung 19: Parametrisierung des Trainingsalgorithmus 48

Abbildung 20: Vergleich der ursprünglichen Ausgabewerte des nichtlinearen dynamischen Systems und der durch das ANN Netz simulierten Ausgabewerte 49

Abbildung 21: Struktur des Programms „ANNSolar“ 54

Abbildung 22: Input-Output-Schnittstelle..... 55

Abbildung 23: Ausgabemodul der ANN-Regelung..... 60

Abbildung 24: Modul ANN_1: Heizkreis und Format der Zeitvariablen..... 61

Abbildung 25: Modul ANN_1: Algorithmus zur Berechnung der Vorlauf Solltemperatur (T_f, t_g).. 62

Abbildung 26: Prinzipieller Verlauf der Fehlerfunktion f mit der Vorlauf Solltemperatur T_f, t_g 64

Abbildung 27: f -Wert des Regelalgorithmus zu acht verschiedenen Zeitpunkten im Januar 2018. Der f -Wert ist ein gewichteter Mittelwert der Abweichung von Prognosewerten und

Sollwerten der Raumtemperatur über die jeweils folgenden drei Stunden. Es wird immer die Vorlauftemperatur eingestellt, bei der der f-Wert das erste Mal einen positiven Wert annimmt. . 65

Abbildung 28: Ansteuerung des Mischventil-Motors..... 68

Abbildung 29: ANN_2: Pelletbrenner 71

Abbildung 30: ANN_2: Pelletbrenner, Algorithmus..... 72

Abbildung 31: ANN_2: Pelletbrenner, Berechnungsbeispiel für $Nb = 4$ 75

Abbildung 32: Messwert, LSI-Anteil, ANN-Anteil und Summe der beiden für T8 (obere Speichertemperatur) an Tag 100 im Trainingsdatensatz der Heizperiode 16/17..... 80

Abbildung 33: Median und 90 %-Quantil für zwei und sechs Stunden Prognosehorizont von T8 im Trainingsverlauf. Es wurden fünf Trainingszyklen durchgeführt; ein Zyklus besteht aus 100 Epochen batch-Training..... 82

Abbildung 34: Messwert, LSI-Anteil, ANN-Anteil und Summe der beiden Anteile für das fertig trainierte Netz zur Vorhersage der Raumtemperatur. Gezeigt ist Tag 25 im Trainingsdatensatz der Heizperiode 16/17..... 83

Abbildung 35: Drei Heizkurven, die für die Erstellung der virtuellen Trainingsdaten genutzt wurden. Die Verwendung von je einer Heizkurve über bzw. unter dem Zielwert der Raumtemperatur von 21°C ermöglicht dem Netz eine Extrapolation über den Bereich der Trainingsdaten hinaus. 87

Abbildung 36: Ein Netzwerk definiert durch m Eingabewerte und 1 verborgene Schicht mit n Neuronen 91

Abbildung 37: Ein Netzwerk definiert durch m Eingabewerte und 2 verborgene Schichten mit jeweils n Neuronen..... 92

Abbildung 38: Es existieren n Wege vom Ausgangsneuron zum gleichen Gewicht der ersten verborgenen Schicht..... 93

Abbildung 39: Testgebäude mit in der Fassade montierten Kollektoren..... 94

Abbildung 40: Vereinfachtes Hydraulikschema der Versuchsanlage..... 95

Abbildung 41: Hydraulik der Versuchsanlage..... 98

Abbildung 42: Flussdiagramm Regelung Solarkreis - Kollektorkreis.....	101
Abbildung 43: Flussdiagramm Regelung Solarkreis – Speicherladekreis	102
Abbildung 44: Flussdiagramm Regelung Kesselkreis Anforderung Kessel (oben), Regelung Volumenstrom (unten)	103
Abbildung 45: Aktoren der ANN-Regelung im realen Testgebäude	104
Abbildung 46: Netztopologie mit n Input Werten, 2 verborgenen Schichten und einem Ausgangswert.....	105
Abbildung 47: ANN Netz mit zwei verborgenen Schichten, dynamischer Rückkopplung und LSI-Ansatz für die die Prognose der Raumtemperatur (oben) und die Speichertemperaturentwicklung (unten).....	106
Abbildung 48: Normierte Solareintrag-Variable (Temperaturunterschied am Kollektor multipliziert mit der normierten Pumpendrehzahl) berechnet aus den Rohdaten aufgetragen gegen die Zeit. Oben: Minütliche Werte. Unten: Geglättet, gleitender Mittelwert über 30 Minuten.....	108
Abbildung 49: Korrelation von gemessener Außentemperatur und Vorhersagen von Wetterbericht und ANN..	109
Abbildung 50: Verteilung der Fehler bei der Prognose der Außentemperatur.....	110
Abbildung 51: Vorhersage der stündlichen Mittelwerte des Solarertrags (Prognose-horizont eine Stunde) mit einem (10-12-12-1) Netz und Vergleich mit den Messdaten	112
Abbildung 52: Messwerte und ANN-Prognosen der Raumtemperaturen für einen Beispieltag (Training mit dem Datensatz der vergangenen 4 Wochen).....	112
Abbildung 53: ANN-Prognosegenauigkeit der Raumtemperaturen für 100 Tage in der Heizsaison (rollierendes Training mit dem Datensatz der vergangenen 4 Wochen).....	113
Abbildung 54: Messwerte und ANN-Prognosen der Raumtemperaturen für 3 Beispieltage (Training mit Jahresdatensatz).....	113
Abbildung 55: ANN-Prognosegenauigkeit der Speichertemperatur für rollierendes Training mit dem Datensatz der vergangene 4 Wochen.....	115
Abbildung 56: Blockschema der Implementierung der I/O Schnittstelle.....	118

Abbildung 57: Heizkreisvorlauftemperaturen von konventioneller Regelung und ANN-Regelung (oben), Soll- und Istwert der Raumtemperatur mit ANN Regelung (mitte) und Kollektortemperatur (unten)..... 122

Abbildung 58: Modell des Gebäudes und des Anlagensystems in Dymola 124

Abbildung 59: Innere Struktur des Gebäudemodells 126

Abbildung 60: Gebäudemodell in Dymola..... 127

Abbildung 61: Innere Struktur des thermischen Speichers in Dymola..... 129

Abbildung 62: Solarkreis in Dymola 130

Abbildung 63: Kesselkreis in Dymola..... 131

Abbildung 64: Kaltwassertemperaturprofil 132

Abbildung 65: Trinkwarmwasserkreis in Dymola..... 132

Abbildung 66: Heizkreis in Dymola 133

Abbildung 67: Wetterdaten Jahr 2011 Freiburg im Breisgau 134

Abbildung 68: Konventioneller Regler des Solarkreises 135

Abbildung 69: Konventioneller Regler des Kesselkreises..... 136

Abbildung 70: Konventioneller Regler des Trinkwarmwasserkreises..... 137

Abbildung 71: Konventioneller Regler des Mischers im Heizkreis..... 137

Abbildung 72: Konventionelle Heizkurve..... 138

Abbildung 73: Konventioneller Regler der Pumpe im Heizkreis..... 139

Abbildung 74: Simulation des ANN-Regelungsprozesses..... 140

Abbildung 75: Umschalter der Regelungssignale in Dymola 142

Abbildung 76: Konventionelle Regelung mit konstanter Vorlauftemperatur..... 146

Abbildung 77: Simulationsergebnisse – konventionelle Regelung mit optimierter Heizkurve.....	148
Abbildung 78: Simulationsergebnisse – ANN Regelung.....	149
Abbildung 79: Monatswerte von $QAux$ und $fsol$ für die 3 Varianten	150
Abbildung 80: Jahreswerte von $QAux$ und $fsol$ für die 3 Varianten	151
Abbildung 81: Jahreswerte von $QAux$ relativ zur Regelung mit konstanter Vorlauftemperatur für die 3 Varianten	152
Abbildung 82: Komfort-Kategorien der drei Regelungsarten in den Varianten I, II und III	154
Abbildung 83: Wärmeerzeugungen durch Kessel und Solarkollektor	156
Abbildung 84: Wärmeverluste im System	157