



ANWENDUNG KÜNSTLICHER NEURONALER NETZE ZUR BESTIMMUNG VON U-WERTEN

Alexander Benz¹, Kay Smarsly², Conrad Völker¹

¹ Bauhaus-Universität Weimar, Deutschland, E-Mail: alexander.benz@uni-weimar.de, conrad.voelker@uni-weimar.de

² Technische Universität Hamburg, Deutschland, E-Mail: kay.smarsly@tuhh.de

Kurzfassung

Die in-situ Bestimmung von U-Werten ist in der Regel mit großen Ungenauigkeiten sowie langen Messdauern verbunden. In der Literatur werden Messzeiträume von 72 Stunden bis zu mehr als zwei Wochen angegeben und Ungenauigkeiten von bis zu 40 %, bezogen auf errechnete Referenzwerte (Evangelisti et al., 2016), genannt. Als Hauptgründe für diese Umstände werden geringe Temperaturgradienten, instationäre Randbedingungen, wechselnde Richtungen des Wärmestroms sowie retardierende Einflüsse durch hohe thermische Speichermassen angeführt.

Künstliche neuronale Netze (KNN) bieten die Möglichkeit, die oben aufgeführten Zusammenhänge zu quantifizieren. Durch die Wahl eines Regressionsansatzes innerhalb der KNN können Einflüsse instationärer Randbedingungen (z.B. Lufttemperatur sowie Solarstrahlung) mit definitionsgemäß stationären Größen, wie dem U-Wert, in Zusammenhang gebracht werden.

Die Autoren stellen in dieser Arbeit die Anwendung von KNN für die Bestimmung von U-Werten auf Grundlage von Simulationsdaten vor. Die Erzeugung der Trainings- und Testdaten erfolgt hierfür durch thermisch-instationäre Bauteilsimulationen auf Basis finiter Elemente. Hierdurch sollen umfangreiche Messungen für den Aufbau der Trainingsdaten entfallen. Im Rahmen dieser Arbeit werden dreilagige neuronale Netze mit 2 bis 20 Neuronen in einem Hidden-Layer für die Regression von U-Werten genutzt. Für eine Referenzierung der vorgeschlagenen Methodik werden die erlangten Regressionsergebnisse mit U-Werten des Mittelwertverfahrens verglichen.

Abstract

The in-situ estimation of U-values is usually associated with high inaccuracies and long measuring campaigns. Literature sources mention time intervals of 72 hours up to more than two weeks as well as derivations of up to 40 % (Evangelisti et al., 2016). Main reasons cited for these circumstances are high thermal capacities, low temperature gradients,

transient boundary conditions and alternating directions of the heat flow.

Artificial neural networks (ANNs) offer the possibility of quantifying the correlations listed above. By choosing a regression-based approach implemented with ANNs, transient environmental influences (e.g., heat flow, air temperature and solar radiation) can be correlated with variables that are by definition stationary, such as the U-value.

In this paper, the authors present the application of ANNs for estimating U-values using simulation data. The training data is generated exclusively by transient simulations of building elements based on finite elements, eliminating the need for extensive measurements to generate the training data. In this work, three-layer neural networks with 2 to 20 neurons within the hidden layer are used for the regression of U-values. The regression results obtained are compared with U-values of the mean value method for referencing the proposed methodology.

Einleitung

Der U-Wert (Gleichung 1) charakterisiert die stationäre Wärmetransmission durch ein Bauteil und wird als allgemein anerkannte Größe, unter anderem durch die Verankerung in (DIN EN ISO 6946, 2018), für den Vergleich zwischen verschiedenen Konstruktionen und zur Bewertung für die Einhaltung regulativer Vorschriften genutzt.

$$U = \frac{1}{R_T} \quad (1)$$

mit: R_T - Wärmedurchgangswiderstand des Bauteils

Für die Berechnung von R_T werden die Wärmedurchlasswiderstände aller Bauteilschichten (R_1, \dots, R_n) um einen äußeren und inneren Wärmeübergangswiderstand (R_{se} und R_{si}) erweitert (siehe Gleichung 2).

$$R_T = R_{si} + R_1 + \dots + R_n + R_{se} \quad (2)$$

Die praktische Anwendung dieses Zusammenhangs setzt jedoch die Kenntnis über den genauen Aufbau einer Konstruktion (Schichtdicken) und deren Wärmeleitfähigkeiten voraus. Für Bestandsgebäude sind diese Werte allerdings häufig unbekannt. Eine in-situ

Messung, beispielsweise beschrieben in (ISO 9869-1, 2014), umgeht dieses Problem und setzt die über die Messdauer (m Messungen) aufgezeichneten Wärmestromdichten q_j in ein Verhältnis zur anliegenden inneren und äußeren Lufttemperatur $\theta_{i,j}$ bzw. $\theta_{e,j}$, wodurch sich der in Gleichung 3 dargestellte Zusammenhang ergibt.

$$U = \frac{\sum_{j=1}^m q_j}{\sum_{j=1}^m (\theta_{i,j} - \theta_{e,j})} \quad (3)$$

Während Gleichung 3 die in-situ Wärmeübergänge berücksichtigt, stellt Gleichung 4 den U-Wert unter Berücksichtigung der Wärmeübergänge nach (DIN EN ISO 6946:2017, 2018) unter Bezugnahme auf die Oberflächentemperaturen ($\theta_{si,j}$ und $\theta_{se,j}$) dar.

$$U = \frac{1}{R_{se} + \frac{\sum_{j=1}^m (\theta_{si,j} - \theta_{se,j})}{\sum_{j=1}^m q_j} + R_{si}} \quad (4)$$

Das bei in-situ Untersuchungen in der Regel vorliegende instationäre thermische Verhalten der untersuchten Konstruktion hat Messdauern zwischen 3 und 14 Tage zur Folge (Bienvenido et al., 2019), wobei nach (ISO 9869-1, 2014) eine minimale Messdauer von 3 Tagen einzuhalten ist.

Eine Verbesserung der in-situ Bestimmungen des U-Wertes ist möglich, wenn das instationäre Verhalten der Konstruktion quantifiziert und in der Auswertung berücksichtigt werden kann. Hierfür schlagen die Autoren der vorliegenden Studie die Nutzung künstlicher neuronaler Netze (KNN) vor. KNN basieren auf einer Vernetzung mehrerer sogenannter Neuronen, wobei ein Input-Layer mit einem Output-Layer verknüpft wird. Im Falle der Regression einer gewählten Größe werden so die gewählten Inputs über Gewichte, repräsentierbar über eine entsprechende Matrix, mit einem Output verknüpft. Werden zwischen Input- und Output-Layer ein oder mehrere sogenannter Hidden-Layer geschaltet, wird ein KNN als Multilayer Perceptron (MLP) bezeichnet. Vorteil der Verwendung solcher Hidden-Layer ist die Möglichkeit nichtlineare Probleme in mehrere lineare Teilprobleme zu unterteilen. Des Weiteren können mehrere hintereinander geschaltete Hidden-Layer unterschiedliche Abstraktionen der Eingangsdaten ausbilden, sodass eine verbesserte Generalisierung auf Grundlage der Eingangsdaten zu erwarten ist.

Durch die Nutzung geeigneter Trainingsdaten (z.B. gemessene Temperaturen oder Wärmeströme) wird ein Regressionswert (z.B. U-Wert) erzeugt. Über einen Vergleich des prognostizierten Wertes mit dem wahren Wert wird über eine Verlustfunktion sowie einen Optimierer im Zuge der sogenannten Backward Propagation die Gewichtsmatrix korrigiert. Durch Iteration dieses Vorgangs wird durch das sogenannte Training eine optimierte Gewichtsmatrix ermittelt.

Nach Abschluss des Trainings steht ein spezialisiertes KNN, in diesem Fall für die Regression des U-Werts aus bestimmten Eingangsgrößen, zur Verfügung.

Stand der Forschung

Eine erste Anwendung von KNN im Rahmen der in-situ Bestimmung des U-Werts wurde von Bienvenido et al. (2019) beschrieben. In dieser Arbeit wurden die Ergebnisse aus 66 in-situ Messungen für das Training von KNN genutzt. Die jeweiligen Messdauern variierten zwischen 4-17 Tage. Als Quelle für die Testdaten wurden wiederum 3 Messungen ausgewählt. Im Rahmen einer Untersuchung des Einflusses der Neuronen im Hidden-Layer Netzarchitekturen wurden dreilagige Netze mit 4 bis 15 Neuronen im Hidden-Layer angewendet sowie 500 bis 120.000 Trainingsepochen durchgeführt. Als leistungsfähigstes KNN wurde in (Bienvenido et al., 2019) eine Architektur mit 14 Neuronen innerhalb des Hidden-Layers angegeben (Leistungsfähigkeit nach dem Training: $R^2 = 0,957$, MAE = 0,050 und RMSE = 0,081). Innerhalb dieser Studie erfolgte jedoch eine unmittelbare Regression des U-Werts, sodass die KNN neben konstruktionsbedingten Einflüssen auf die Messung auch veränderliche Wärmeübergänge, Randbedingungen sowie Fehler während der Messung (z.B. den zusätzlichen Wärmeübergangswiderstand zwischen Oberfläche und Sensor) widerspiegeln. Des Weiteren basiert dieser Ansatz auf der Analyse gemessener Zeitreihen, die unter entsprechendem Zeitaufwand und Einschränkungen der Gebäudenutzung entstanden sind.

Methodik

Im Rahmen dieser Studie werden für den Aufbau der Trainings- und Testdaten synthetische Daten, d.h. Ergebnisse (Oberflächentemperaturen sowie Wärmestromdichte) numerischer Simulationen des transienten Bauteilverhaltens, genutzt. Hierauf basierend untersuchen die Autoren die Möglichkeit, mithilfe eines KNNs eine Regression von U-Werten umzusetzen. Motivation für die Nutzung von Simulationsergebnissen ist der Umstand, dass der Aufbau und insbesondere die gezielte Erweiterung von Trainingsdaten zur Verbesserung der Regressionsergebnisse durch in-situ Messungen vergleichsweise zeitaufwendig ist. Zudem liegen in der Regel keine gesicherten Materialkennwerte der untersuchten Konstruktionen vor, was sich in Kombination mit Messungenauigkeiten negativ auf die Regressionsergebnisse auswirken kann.

Gegenstand der vorliegenden Untersuchung sind verschiedene bauzeittypische Konstruktionen für Außenwände, aufgeführt in (Loga, 2015). Diese werden modelliert und unter transienten Randbedingungen hinsichtlich des Wärmestroms simuliert. Zeitliche Verläufe der äußeren Randbedingungen werden den Testreferenzjahren von (Deutscher Wetterdienst, 2014) entnommen. Für die Berücksichtigung der transienten Einflüsse auf der Innenseite der Bauteile werden die

Ergebnisse der Arbeiten von (Hofmann et al., 2022) genutzt. Diese stellen auf Basis empirischer Untersuchungen zeitabhängige Regressionsansätze der Innenlufttemperatur zur Verfügung und erlauben somit eine zeitabhängige Modellierung der Innenraumtemperatur. Eine Visualisierung dieser Verläufe stellt Abbildung 1 dar.

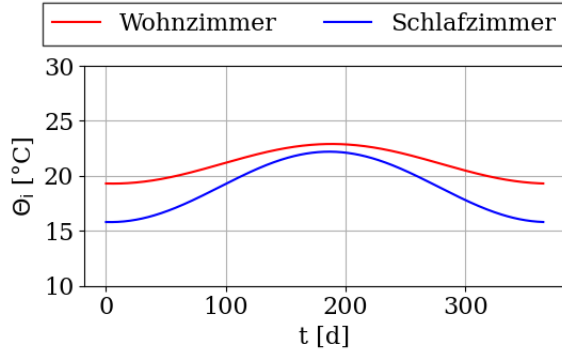


Abbildung 1: Modell des dynamischen Innenraumklimas für zwei Nutzungsszenarien durch Regression nach (Hofmann et al., 2022)

Basierend auf den Simulationsergebnissen werden die in Tabelle 1 aufgeführten Simulationsergebnisse als Eingangsgrößen für die KNN genutzt. Weitere Eingangsgrößen werden als arithmetische Mittelwerte über 24 h vor dem jeweils untersuchten Zeitpunkt errechnet. Dies stellt eine gewisse Kontextualisierung der Daten im Sinne der zeitlichen Entwicklung der Zustandsgrößen dar und soll den Informationsgehalt der Eingangsgrößen erhöhen.

Tabelle 1: Eingangsgrößen der KNN

Symbol	Beschreibung
Δt	Zeitintervall zwischen zwei Simulationsergebnissen
θ_{si}	innere Oberflächentemperatur
θ_{se}	äußere Oberflächentemperatur
q_{si}	Wärmestromdichte (bidirektional) der Wandinnenoberfläche
$d\theta_{si}$	arithmetischer Mittelwert der inneren Oberflächentemperatur in den 24 h vor dem jeweils untersuchten Zustand
$d\theta_{se}$	arithmetischer Mittelwert der äußeren Oberflächentemperatur in den 24 h vor dem jeweils untersuchten Zustand
dq_{si}	arithmetischer Mittelwert der innenseitigen Wärmestromdichte in den 24 h vor dem jeweils untersuchten Zustand

Als Zielwert, bzw. Prognosewert, der KNN wird in der vorliegenden Studie der Wärmedurchgangswiderstand (R-Wert) des jeweiligen Bauteils definiert, sodass im Gegensatz zu (Bienvenido et al., 2019) ein R-Wert (R_{MLP}) prognostiziert wird. Aus diesem kann im weiteren Verlauf, unter Berücksichtigung normierter

Werte für R_{si} sowie R_{se} , (DIN EN ISO 6946, 2018) ein normgerechter U-Wert (U_{MLP}) angegeben werden. Eine direkte Regression des U-Werts (U_{MLP}) hätte zur Folge, dass unter anderem auch Einflüsse der beidseitigen Wärmeübergänge durch das KNN aufgenommen und in den Gewichten abgebildet werden. Die Anzahl der Neuronen des Input-Layers ergibt sich in Folge der gewählten Eingangsgrößen zu 7 Neuronen und einem Bias-Neuron. Im darauffolgenden Hidden-Layer wird die Anzahl der Neuronen zwischen 2 und 20, jeweils mit einem Bias-Neuron, variiert. Es ergibt sich die in Abbildung 2 dargestellte schematische MLP-Architektur.




Abbildung 2: Schematische Darstellung der gewählten MLP-Architektur

Implementierung

Die Umsetzung der transienten Bauteilsimulationen erfolgte in ANSYS Mechanical innerhalb des Moduls „Transient Thermal“. Die Modellbildung verlief für die Trainings- und Testdaten in analoger Art. Unter der idealisierenden Annahme eines eindimensionalen Wärmedurchgangs durch das Bauteil wurden für die Simulationen zweidimensionale Ausschnitte der Außenwände mit adiabaten Randbedingungen an den Schnittkanten modelliert. Die Simulationsergebnisse für neun verschiedene Außenwandkonstruktionen dienen hierbei als Grundlage für die Trainingsdurchläufe und umfassen U-Werte im Intervall von $0,12 \frac{W}{m^2K}$ bis $2,00 \frac{W}{m^2K}$. Dieses Intervall umfasst ausgewählte typische Konstruktionen der Bauzeitalter von vor 1859 bis 2001, sowohl in bauzeitlichen Zuständen als auch in sanierten Zuständen (nachträglich gedämmt). Hierbei werden verschiedene Materialien sowie Positionen der Wärmedämmung in die Trainingsdaten integriert. Abbildung 3 stellt die gewählten Trainingsfälle sowie

die entsprechenden U-Werte dar. Die Konstruktionen der drei Testfälle (K1, K2 und K3) gliedern sich in das zuvor genannte Intervall ein und stellen ihrerseits wiederum individuelle (d.h. von den Trainingsdaten abweichende) Konstruktionen dar. K1 stellt eine unsanierte Außenwand zwischen 1860-1918 dar, K2 repräsentiert eine gedämmte Außenwand der Baualtersklasse 1919-1948 und K3 stellt eine zweischalige Außenwandkonstruktion mit zwei Dämmebenen aus der Baualtersklasse 1995-2001 dar. Eine Übersicht der modellierten Querschnitte mit entsprechend referenzierten U-Werten nach (Loga, 2015), bezeichnet als U_{IWU} , ist in Abbildung 3 dargestellt.


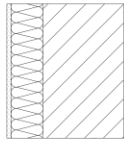



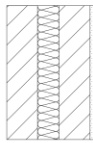
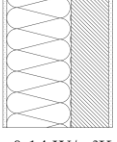
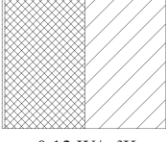
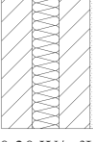

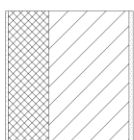
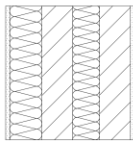





Training			
U_{IWU}	 2,00 W/m ² K	 0,25 W/m ² K	 1,40 W/m ² K
U_{IWU}	 0,36 W/m ² K	 0,13 W/m ² K	 0,36 W/m ² K
U_{IWU}	 0,14 W/m ² K	 0,12 W/m ² K	 0,30 W/m ² K
Test			
U_{IWU}	 1,61 W/m ² K	 0,23 W/m ² K	 0,15 W/m ² K
	 Gefach	 Mineralwolle	 Putz
	 Mauerwerk	 EPS-Dämmung	

Abbildung 3: Querschnitte und referenzierte U-Werte der untersuchten Trainings- und Testfälle

Für die geometrische Diskretisierung der untersuchten Konstruktionen werden quadratische finite Elemente gewählt (beispielhafte Darstellung in Abbildung 4). Um oberflächennahe Einflüsse der transienten Randbedingungen an den Oberflächen der Konstruktionen bestmöglich abbilden zu können, wird das Netz der finiten Elemente an diesen Stellen lokal durch einen graduellen Verlauf verdichtet. Die thermischen Kennwerte der Materialien für die Modellierung der Konstruktionen wurden unter der Annahme konstanter und feuchteunabhängiger Werte aus (Fraunhofer-Institut für Bauphysik IBP, 2023) entnommen. Eine Kombination dieser Werte mit entsprechenden Schichtdicken

ergeben die zuvor aufgeführten Referenzwerte (U_{IWU}).




Abbildung 4: Finite Elemente, dargestellt über den Querschnitt der Konstruktion K2 (vgl. Abbildung 3)

Der äußere konvektive Wärmeübergangskoeffizient h_{ce} wurde über den in (DIN EN ISO 6946:2017, 2018) aufgeführten Zusammenhang

$$h_{ce} = 4 + 4v \quad (5)$$

berücksichtigt, wobei v als Windgeschwindigkeit in $\frac{m}{s}$ linear in die Gleichung 5 eingeht. Die entsprechenden Werte der Windgeschwindigkeit wurden für den Trainingsprozess dem Klimadatensatz (Deutscher Wetterdienst, 2014) für die Klimaregion 01 (Nordseeküste) entnommen. Um einen zusätzlichen Unterschied zwischen Trainings- und Testdaten zu generieren, wurde für die Bauteilsimulationen der Testdaten auf den Klimadatensatz der Klimaregion 02 (Ostseeküste) zurückgegriffen. Die auf die Oberfläche auftreffende Solarstrahlung wurde für eine nach Norden ausgerichtete Fassade der Klimaregion 01 (für Trainingsdaten) bzw. Klimaregion 02 (für Testdaten) in das Modell integriert. Die nach Norden orientierte Ausrichtung entspricht der empfohlenen Orientierung für möglichst stabile in-situ Bestimmungen des U-Werts (Bienvenido et al., 2019; Gaspar et al., 2016). Weitere strahlungsinduzierte Wärmeübergänge werden nicht berücksichtigt. Für die Innenoberfläche der simulierten Bauteile wird der Wärmeübergang infolge Strahlung nicht berücksichtigt und lediglich ein konvektiver Wärmeübergang mit einem konstanten Wärmeübergangskoeffizienten $h_{ci} = 2,5 \frac{W}{m^2K}$ nach (DIN EN ISO 6946:2017, 2018) modelliert.

Die Temperaturrandbedingungen für den Außenraum werden analog zur Solarstrahlung für die Klimaregion 01 aus (Deutscher Wetterdienst, 2014) entnommen. Für den Innenraum wird eine Nutzung als Wohnzimmer angenommen und entsprechend (Hofmann et al., 2022) ebenfalls als transiente Randbedingung modelliert. Als Simulationszeitraum wird der 1. Januar bis

31. März gewählt, dies entspricht nach Erfahrungen der Autoren aus vorangegangenen Studien (Benz et al., 2017; Benz et al., 2021) einem Zeitraum in dem entsprechend niedrige Außentemperaturen für eine Bestimmung des U-Werts zu erwarten sind.

Um das für in-situ Messungen übliche Messintervall von 5 bis 15 Minuten (Bienvenido et al., 2019; Gaspar et al., 2016) auch in den Simulationen abzubilden, werden die transienten Zustandsgrößen (Temperatur und Wärmestromdichte) über die Definition entsprechender Teilschritte inkrementell in 10-minütiger Auflösung auf das Modell aufgeprägt. Es ergibt sich aus jeder Simulation eine Zeitreihe über 2190 h, wobei durch die erhöhte Auflösung 13.140 einzelne Datensätze (bestehend aus θ_{si} , θ_{se} , q_{si}) resultieren. Für die Beschreibung des Initialzustands wird das erste Zeitinkrement als stationärer Zustand berechnet, hierauf basierend werden alle weiteren Zeitinkremente als transiente Zustände errechnet. Die Entnahme der Eingangsgrößen der KNN (siehe Tabelle 1) erfolgt jeweils an den Randelementen des modellierten Querschnitts. Diese Elemente stellen im Übergangsbereich zwischen Wandquerschnitt und Umgebung durch ihre reduzierte Elementgröße die Oberfläche näherungsweise dar (siehe Abbildung 4).

Die exakte vertikale Position (Höhe an der Außenoberfläche) ist hierbei aufgrund des idealisierten eindimensionalen Wärmestroms irrelevant.

Für die Modellierung der KNN wird die Deep-Learning-Bibliothek „Keras“ genutzt. Der Trainingsprozess wurde mit Zeitreihen aus 9 Bauteilsimulationen aufgebaut, siehe Abbildung 3. Als Optimierungsfunktion wird Stochastic Gradient Descent mit einer Lernrate von 0,3 und einem Momentum von 0,2 angewendet. Des Weiteren werden die Trainingsdaten nach einer Normalisierung über eine 10-fold Cross Validation in das KNN eingegeben. Die Anzahl der Trainingsperioden liegt bei 1.000. Im Input- und Hidden-Layer wird als Aktivierungsfunktion eine Sigmoidfunktion genutzt. Der Output-Layer wird mithilfe einer linearen Aktivierungsfunktion ausgebildet. Die abschließende Bewertung der Regression durch das KNN wird über die nachfolgenden Kennwerte vorgenommen (Gleichungen 6-8).

$$R^2 = 1 - \frac{\sum_{i=1}^n (R_{MLP} - R_{ref})^2}{\sum_{i=1}^n (R_{MLP} - \bar{R}_{ref})^2} \quad (6)$$

$$MAE = \frac{\sum_{i=1}^n |R_{MLP} - R_{ref}|}{n} \quad (7)$$

$$RMSE = \left(\frac{\sum_{i=1}^n (R_{MLP} - R_{ref})^2}{\sum_{i=1}^n (R_{MLP} - \bar{R}_{ref})^2} \right)^{1/2} \quad (8)$$

In Gleichungen 6-8 bezeichnet R^2 das Bestimmtheitsmaß, MAE den mittleren absoluten Fehler und RMSE die Wurzel des mittleren quadratischen Fehlers. Für

R^2 wird ein Wert nahe 1 angestrebt, wohingegen für MAE sowie RMSE ein Wert nahe 0 als bestes Ergebnis zu interpretieren ist.

Ergebnisse und Diskussion

Die aus den transienten Simulationen resultierenden Zeitreihen werden im weiteren Verlauf als mögliche Ergebnisse aus Messungen interpretiert und nach Gleichung 4 für die Errechnung des U-Werts genutzt.




Abbildung 6: U-Werte nach Gleichung 4, aufgetragen über die Zeitschritte der Simulation (unterbrochene rote Linie: Referenzwert U_{IWU})

Die hieraus resultierenden Ergebnisse sind in Abbildung 6 in Abhängigkeit des Simulationsverlaufs aufgetragen.

Es zeigt sich, dass trotz idealisierter Bedingungen dieser Studie zu Beginn ausgeprägte Oszillationen des errechneten U-Werts vorliegen. Im weiteren Verlauf der

Simulation verringert sich die Amplitude dieser Oszillationen, wodurch sich der errechnete U-Wert dem Referenzwert U_{IWU} annähert. Des Weiteren ist festzustellen, dass für geringere U-Werte die Amplitude der Oszillation geringer ausfällt. Dieser Umstand ist damit zu begründen, dass in den betreffenden Konstruktionen der Hauptteil der thermischen Masse stärker von den äußeren Temperatureinflüssen entkoppelt ist und als Resultat eine konstantere Wärmestromdichte zu erwarten ist.

Des Weiteren ist anzumerken, dass die errechneten U-Werte aufgrund des endlichen Simulationszeitraums sowie des numerischen Ansatzes Ungenauigkeiten unterliegen. Diese fallen im Falle der betrachteten Konstruktionen zwar verhältnismäßig gering aus, können jedoch in Abbildung 6 durch geringfügig zu groß errechnete U-Werte abgelesen werden. Nicht zuletzt aufgrund der begrenzten Fallstudie mit 3 Konstruktionen lässt sich keine abschließende systematische Erklärung für diese beobachteten Abweichungen finden.

Mittels der in Gleichungen 6 bis 8 aufgeführten Kennwerte werden nachfolgend die Regressionen der trainierten MLP bewertet. Abbildung 7 führt hierfür eine Übersicht dieser Kennwerte in Abhängigkeit der Neuronen innerhalb des Hidden-Layers auf. Angegeben sind die Werte nach jeweils 1.000 Trainingsdurchläufen. Bereits MLP mit 2 Neuronen scheinen in der Lage zu sein, die Regression von U-Werten zu realisieren. Die Leistungsfähigkeit der Regression, gemessen an den zuvor genannten Kennwerten, nimmt mit zunehmender Anzahl der Neuronen etwas zu. Bei einer Konstellation von 8 Neuronen innerhalb des Hidden-Layers ist im Vergleich zu den übrigen Konstellationen ein geringfügig besseres Ergebnis zu verzeichnen (siehe rote Markierung in Abbildung 7). Aus diesem Grund wird dieses MLP für weitere Untersuchungen in dieser Studie genutzt.

In Abbildung 8 werden daher für 8 Neuronen innerhalb des Hidden-Layers die Verläufe der gewählten Verlustfunktion (mittlerer quadratischer Fehler, MSE) sowie für R^2 über den Trainings- und Validierungsverlauf dargestellt. Als Verlustfunktion wurde der mittlere quadratische Fehler (MSE) gewählt, dieser wichtet im Gegensatz zu MAE ausgeprägte Prognosefehler deutlich stärker als geringere Abweichungen der Prognose, sodass eine schnellere Konvergenz des Trainingsprozesses zu erwarten ist.




Abbildung 7: Regressionsfehler nach 1.000 Trainingsepochen in Abhängigkeit der Anzahl der Neuronen innerhalb des Hidden-Layers




Abbildung 8: Verhalten des MLP während des Trainings- bzw. Validierungsprozesses für 8 Neuronen innerhalb des Hidden-Layers

Mit fortschreitendem Trainingsverlauf kann innerhalb der ersten ca. 100 Epochen eine signifikante Reduzierung des MSE beobachtet werden. Mit weiterem Training konvergiert die Verlustfunktion gegen 0, wohingegen R^2 zunächst stetig zunimmt und in ein konvergierendes Verhalten (Grenzwert siehe Abbildung 7) übergeht. Die beobachteten Konvergenzen treffen hierbei für den Trainings- und Validierungsprozess zu, sodass eine Überanpassung auf den wiederholt eingehenden Trainingsdaten unwahrscheinlich ist.

Nachdem das Verhalten verschiedener MLP für das Training untersucht und dargestellt wurde, stellt Tabelle 4 die Regressionsfähigkeit bezüglich unbekannter Werte dar. Sowohl für das Verfahren nach Gleichung 4 als auch für die Prognose des trainierten MLP zeigen sich für vergleichsweise niedrige U-Werte (K2, K3) bessere Ergebnisse als für den höheren U-Wert im Testfall K1. Die Begründung hierfür kann ebenfalls in der stärkeren Entkopplung von externen Temperatureinflüssen bei niedrigen U-Werten gesehen werden. Es ist zudem festzuhalten, dass mit niedrigeren U-Werten der prognostizierte U-Wert des MLP näher am Referenzwert liegt als nach dem etablierten Verfahren nach (DIN EN ISO 6946:2017, 2018).

Tabelle 4: Übersicht der U-Werte nach IWU (Loga, 2015), Berechnung nach Gleichung 4 sowie als Ergebnis des MLP

	U [W/m ² K]		
	U _{IWU}	U _{DIN6946}	U _{MLP}
K1	1,61	1,62±0,014	1,53±0,140
K2	0,23	0,24±0,006	0,23±0,003
K3	0,15	0,15±0,003	0,15±0,001

Fazit

Mit diesem Beitrag wird die Verwendung von KNN, im Speziellen die Nutzung eines MLP mit einem Hidden-Layer, zur Bestimmung des U-Werts unter transienten Randbedingungen vorgeschlagen. Als Trainingsdaten wurden die Ergebnisse numerischer Bauteilsimulationen genutzt. Im Zuge einer Parameterstudie wurde die, für die gewählte Problemstellung, optimale Anzahl der Neuronen innerhalb des MLP bestimmt. Aus dieser Studie ging unter Nutzung entsprechender Kennwerte ein MLP mit 8 Neuronen im Hidden-Layer als beste Architektur hervor. Für dieses Netzwerk ergibt sich ein Regressionsergebnis hinsichtlich R² von 0,989 (MAE = 0,071, RMSE = 0,102).

Durch die Gegenüberstellung der Ergebnisse aus einer Bestimmung des U-Werts nach (DIN EN ISO 6946:2017, 2018) konnte neben der grundsätzlichen Qualität der Simulationsergebnisse auch die potentielle Eignung von KNN zur Regression von in-situ U-Werten aufgezeigt werden. Für niedrige U-Werte übersteigt die Genauigkeit des MLP zudem die des etablierten Mittelwertverfahrens nach (DIN EN ISO 6946:2017, 2018).

Einschränkend hinsichtlich der in Tabelle 4 dargestellten Ergebnissen, ist anzumerken, dass das gewählte Modell zur Beschreibung des Innenraumklimas keine Schwankungen auf Tagesebene berücksichtigt. Hieraus ergibt sich im Gegensatz zu in-situ Messungen eine wesentliche Erleichterung bei der Bestimmung des U-Werts mit dem etablierten Mittelwertverfahren nach (DIN EN ISO 6946:2017, 2018).

Des Weiteren unterliegen Regressionen des U-Werts außerhalb des genutzten Trainingsintervalls

(0,10-2,00 W/m²K) vermutlich enormen Unsicherheiten.

Ausblick

In weiterführenden Arbeiten streben die Autoren dieser Studie die Erweiterung und Verallgemeinerung des beschriebenen Ansatzes an. Hierfür sollte die Varianz der transienten Bauteilsimulationen erhöht werden. Dies kann durch eine Diversifizierung der simulierten Konstruktionen erreicht werden, sodass neben der Massivbauweise auch Varianten des Holzbaus oder hybride Bauweisen untersucht werden müssten. Auch die Integration statistischer Streuungen der Materialkennwerte sowie die Berücksichtigung zeitabhängiger Verläufe der Innenraumtemperatur auf Tagesebene und detailliertere Strahlungsprozesse an beiden Oberflächen sollte in Erwägung gezogen werden. Im Sinne einer Qualitätssicherung sollten zudem Mesh-Independence-Tests in Kombination mit Validierungen anhand von Messergebnissen vorgenommen werden.

Um eine stärkere Kontextualisierung der einzelnen Zeitschritte zu ermöglichen, könnten für die Regression zunächst weitere Eingangsgrößen auf Basis der Simulationsergebnisse genutzt werden (z.B. Mittelwerte über verschiedene Zeitintervalle zur Charakterisierung periodischer Schwankungen). Im Zuge dessen sollten auch entsprechende Studien zum Einfluss der Hyperparameter (z.B. Lernrate, Verlustfunktion, Optimierer) vorgenommen werden. Weitere Untersuchungen können zudem die Potentiale anderer Arten neuronaler Netze (z.B. rekurrente neuronale Netze) zum Gegenstand haben und entsprechende Verbesserungen der vorgestellten Methodik aufzeigen.

Die Praxistauglichkeit und potentiellen Beschränkungen der beschriebenen Methodik müssen zudem durch umfangreiche Messkampagnen, sowohl unter Labor-, als auch unter in-situ Bedingungen, evaluiert werden.

Literatur

- Benz, A. et al., 2017. Thermografische Abschätzung der thermischen Eigenschaften von Gebäudehüllen zur Verwendung als Eingangsparameter bei der energetischen Gebäudesimulation. Tagungsband der Bauphysiktag 2017.
- Benz, A. et al., 2021. Framework for a UAS-based assessment of energy performance of buildings. *Energy and Buildings* 250, 111266.
- Bienvenido-Huertas, D. et al., 2019. Applying an artificial neural network to assess thermal transmittance in walls by means of the thermometric method. *Applied Energy* 233-234, p. 1-14.
- DIN EN ISO 6946, 2018. Bauteile - Wärmedurchlasswiderstand und Wärmedurchgangskoeffizient - Berechnungsverfahren.
- Deutscher Wetterdienst, 2014. Testreferenzjahre von Deutschland für mittlere, extreme und zukünftige Witterungsverhältnisse, DWD, Offenbach.
- Evangelisti, L. et al., 2016. Experimental investigation of the influence of convective and radiative heat transfers on thermal transmittance measurements. *International Communications in Heat and Mass Transfer* (78), S. 214-223.
- Fraunhofer-Institut für Bauphysik IBP, 2023. MASEA - Materialdatensammlung für die energetische Altbausanierung. <https://www.masea-ensan.com/>, letzter Zugriff am 6.12.2023.
- Gaspar, K. et al., 2016. A comparison of standardized calculation methods for in situ measurements of façades U-value. *Energy and Buildings* 130, S. 592-599.
- Hofmann, M. et al., 2022. Dependencies of the indoor climate on the course of the seasons and derivation of regressions from long-term measurements. *Indoor air*, Vol. 32 [6].
- ISO 9869-1, 2014. Thermal insulation – Building elements – In-situ measurement of thermal resistance and thermal transmittance, Part 1: Heat flow meter method.
- Loga, T., 2015. Deutsche Wohngebäudetypologie – Beispielhafte Maßnahmen zur Verbesserung der Energieeffizienz von typischen Wohngebäuden ; erarbeitet im Rahmen der EU-Projekte TABULA, Institut Wohnen und Umwelt. IWU, Darmstadt.