

ANWENDUNG VON METHODEN DES MASCHINELLEN LERNENS ZUR GANZHEITLICHEN RAUMREGELUNG

S. Kalmbach¹, W. Haase¹ und W. Sobek^{1,2}

¹Institut für Leichtbau Entwerfen und Konstruieren,
Universität Stuttgart, Stuttgart, Deutschland

²Werner Sobek AG, Stuttgart, Deutschland

KURZFASSUNG

In diesem Beitrag wird eine von den Autoren erstellte, sich selbst konditionierende Raumregelung vorgestellt, die Methoden aus dem Bereich des maschinellen Lernens anwendet.

Das sogenannte bestärkende Lernen wurde mit Simulationen zum Raumklima und der Beleuchtung für einen Testraum verknüpft mit dem Ziel, eine künstliche neuronale Netzstruktur zu trainieren.

In einer Simulation konnte gezeigt werden, dass es mit Methoden des bestärkenden Lernens möglich ist, ein künstliches neuronales Netz so zu trainieren, dass die Regelung einer adaptiven Verglasung, der künstlichen Beleuchtung sowie der Heizung und Kühlung mit guter Effizienz ausgeführt werden kann.

ABSTRACT

This paper presents a self-conditioning room control system created by the authors, which uses methods from the field of machine learning.

The so-called reinforcement learning was combined with simulations of indoor climate and lighting for a test room with the aim of training an artificial neural network structure.

In a simulation it could be shown that it is possible to train an artificial neural network with methods of reinforcement learning in a way that the control of adaptive glazing, artificial lighting, heating and cooling can be performed with good efficiency.

EINFÜHRUNG

Die Anforderungen an Raum- und Gebäuderegeln sind vielfältig. Zum einen muss auf einen sparsamen Umgang mit der zur Konditionierung eingesetzten Energie geachtet werden, um Ressourcen zu schonen und Betriebskosten zu senken, zum anderen soll die Behaglichkeit für die Nutzer sichergestellt werden.

Um diesen Anforderungen gerecht zu werden, sind ganzheitliche Konzepte der Gebäuderegeln, welche möglichst viele Einflussparameter berücksichtigen, erforderlich.

Der von den Autoren untersuchte Ansatz zur Lösung dieser Aufgabe basiert auf der Anwendung von Methoden des bestärkenden Lernens zur Regulierung der Innenraumtemperatur, zur Ansteuerung der Innenraumbeleuchtung sowie zum Dimmen einer adaptiven Verglasung, deren Transmissionsgrad einstellbar ist.

Umgesetzt wurde die Regelung in Form einer realitätsnahen und instationären Simulation mit Kopplung von Gebäudeklima- und Tageslichtberechnungen. Simuliert wurde ein räumliches Gebäudemodell, welches sich in Geometrie und Topologie an einem Fassadentestgebäude, welches vom Institut für Leichtbau Entwerfen und Konstruieren (ILEK) der Universität Stuttgart betrieben wird, orientiert.

Abbildung 1 zeigt die am gesamten Testgebäude sowie die für den Testraum verfügbare Sensorik des Fassadentestgebäudes. Die mit Bezeichnungen gekennzeichneten Messpunkte wurden in die Simulation und Regelung mit aufgenommen.

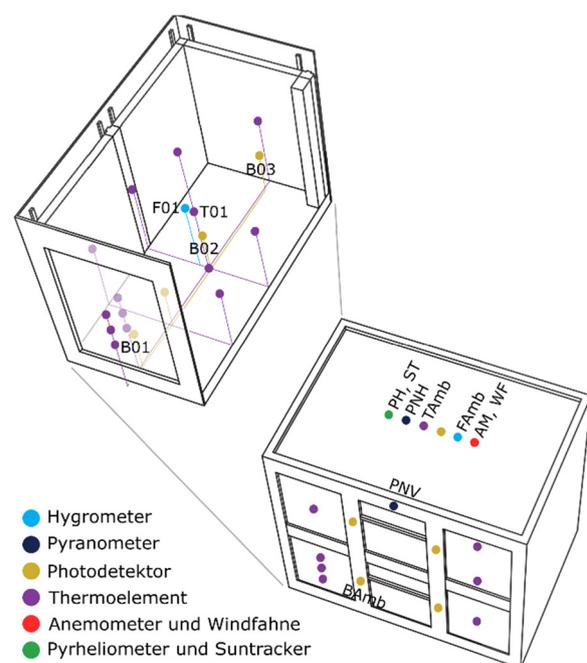


Abbildung 1: Sensorübersicht des Referenzraumes
(Haase u. Husser 2018)

Die zu entwickelnde Regelung sollte in der Lage sein, kontinuierlich, unter Einbeziehung von Informationen der Sensorik und anhand von beleuchtungstechnischen und thermischen Kriterien ihre Regelungszustände der technischen Gebäudeausstattung anpassen und optimieren zu können.

Als beleuchtungstechnisches Kriterium ist eine Beleuchtungsstärke von 500 lx auf Grundlage der DIN EN 12464-1 einzuhalten. Die thermischen Randbedingungen beziehen sich auf einen einzuhaltenen Temperaturbereich im Innenraum, welcher von 20 °C bis 26 °C nach DIN EN 12831-1 definiert ist.

Der Regelung stehen zur Konditionierung des Innenraums die in Abbildung 2 dargestellten Komponenten zur Verfügung. Dies sind an den Innenwänden angebrachte Kapillarrohrmatten zur flächigen Heizung und Kühlung, drei dimmbare Beleuchtungsmittel, welche zur Ansteuerung in zwei Gruppen eingeteilt sind, sowie eine in der Licht- und Energiedurchlässigkeit regelbare Verglasung auf Flüssigkristallbasis.

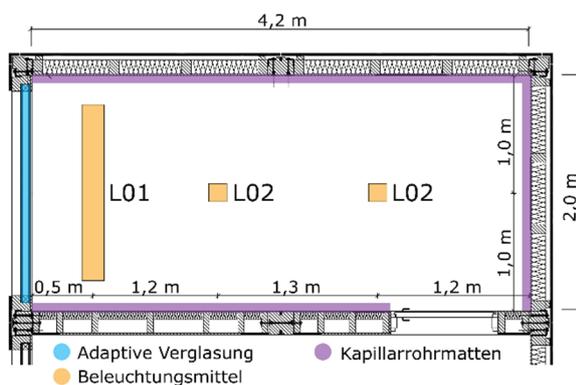


Abbildung 2: Übersicht der regelbaren technischen Ausstattung des Referenzraumes

KÜNSTLICHE NEURONALE NETZSTRUKTUR

In dem Bestreben, das Verhalten von Neuronen und ihr Zusammenspiel in Nervensystemen nachzubilden, repräsentieren künstliche neuronale Netze eine vereinfachte, in mathematische Funktionen überführte Analogie eines biologischen Systems (Ertel 2016).

Diese Netze sind in der Lage, Eingabedaten (Informationen) zu verarbeiten und daraus Ausgabedaten zu liefern. Eingabedaten im Sinne der Regelungsaufgabe sind beispielsweise die Innenraumtemperatur oder die relative Umgebungsluftfeuchtigkeit. Ausgabedaten hingegen sind Einstellungen wie der Schaltzustand der adaptiven Verglasung zur Regelung der Transmission.

Eine Vernetzung von mehreren künstlichen Neuronen bildet ein künstliches neuronales Netz. Diese

Vernetzungen können unterschiedlichste Ausprägungen haben.

Im Rahmen dieser Untersuchung wurde ein mehrschichtiges feedforward-Netz verwendet. Bei diesem ist jedes Neuron aus einer Schicht mit allen Neuronen der nächsten sowie der vorangegangenen Schicht verbunden. Um eine Ausgabe aus einer gegebenen Eingabe zu erhalten, werden die Informationen von Schicht zu Schicht weitergegeben. Jeder Eingabewert eines Neurons ist dabei mit einer Gewichtung (engl. Weight) versehen, jedem Neuron wird ein Schwellwert (engl. Bias) addiert. Die Summe dieser Terme bildet die Eingabe einer Funktion, welche als Aktivierungsfunktion bezeichnet wird. Die Ausgabe eines Neurons ist somit das Ergebnis seiner Aktivierungsfunktion (Frochte 2019).

In Abbildung 3 sind die Abhängigkeiten eines einzelnen künstlichen Neurons von dessen Eingabewerten, der Gewichte sowie der Aktivierungsfunktion dargestellt.

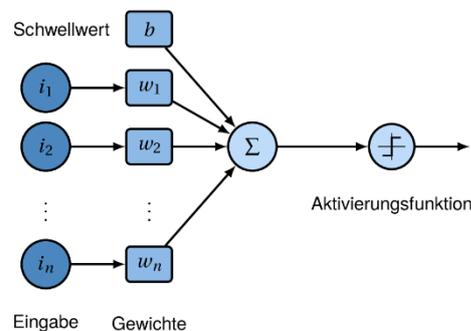


Abbildung 3: Mathematisches Modell eines künstlichen Neurons (Frochte 2019)

Ein mehrschichtiges Netz ist gegeben, sobald das neuronale Netz mehr als eine verborgene Neuronenschicht (engl. Hidden Layer) besitzt (Dutta 2018).

Die vorgestellte Regelung verwendet eine Netzstruktur mit 25 Eingangswerten (siehe Tabelle 1), zwei verborgenen Neuronenschichten mit jeweils 64 Neuronen sowie zehn Ausgabewerten, mit welchen fünf Regelzustände ermittelt werden. Abbildung 4 zeigt den schematischen Aufbau der Netzstruktur.

Die in Tabelle dargestellten Regelzustände werden anhand einer Wahrscheinlichkeitsverteilung, der Gaußschen Normalverteilung, ermittelt. Für jeden Regelzustand repräsentieren zwei Ausgabewerte des neuronalen Netzes die Standardabweichung und den Erwartungswert der Normalverteilung. Dies ermöglicht die Ausgabe von kontinuierlichen Werten, welche zur Definition der Regelzustände herangezogen werden (Sutton u. Barto 2018).

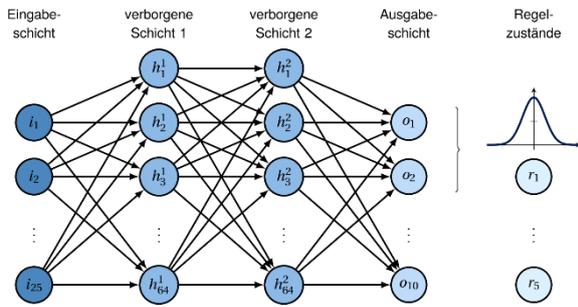


Abbildung 4: Schematischer Aufbau des untersuchten neuronalen Netzes

Als Eingabewerte werden dem künstlichen neuronalen Netz die in Tabelle 1 aufgelisteten Parameter übermittelt.

Tabelle 1: Eingabeparameter des künstlichen neuronalen Netzes

Bezeichnung	Einheit
Windgeschwindigkeit (AM)	m/s
Windrichtung (WF)	°
Beleuchtungsstärke auf horizontalen Messpunkt BAMB	lx
Beleuchtungsstärke auf horizontalen Messpunkt B01	lx
Beleuchtungsstärke auf horizontalen Messpunkt B02	lx
Beleuchtungsstärke auf horizontalen Messpunkt B03	lx
Relative Umgebungsluftfeuchtigkeit außen (Famb)	%
Schwellwert der Temperatur zum Aktivieren der Heizung	°C
Schwellwert der Temperatur zum Aktivieren der Kühlung	°C
Schaltzustand der Leuchtmittelgruppe L01	-
Schaltzustand der Leuchtmittelgruppe L02	-
Unterer Sollwert der Beleuchtungsstärke	lx
Direktstrahlung auf das Pyrheliometer (PH)	W/m ²
Globalstrahlung auf horizontales Pyranometer (PNH)	W/m ²
Globalstrahlung auf vertikales Pyranometer (PNV)	W/m ²
Anwesenheit von Personen	-
Tag des aktuellen Jahres als Dezimalzahl	d
Stunde des aktuellen Tages	h
Kühlenergiebedarf	kJ/h
Heizenergiebedarf	kJ/h
Energiebedarf der Beleuchtung	kW
Relative Innenraumluftfeuchtigkeit (F01)	%
Verschattungszustand der adaptiven Verglasung	-
Innenraumlufttemperatur (T01)	°C
Umgebungslufttemperatur außen (TAmb)	°C

Tabelle 2 stellt die durch das neuronale Netz ermittelten Regelzustände zur Steuerung der technischen Ausstattung dar.

Tabelle 2: Parameter zur Regelung der technischen Ausstattung

Bezeichnung	Einheit
Schwellwert der Temperatur zum Aktivieren der Heizung	°C
Schwellwert der Temperatur zum Aktivieren der Kühlung	°C
Schaltzustand der adaptiven Verglasung	-
Schaltzustand der Leuchtmittelgruppe L01	-
Schaltzustand der Leuchtmittelgruppe L02	-

Die Anwendung von Methoden des maschinellen Lernens lässt sich in drei Bereiche unterteilen. Diese sind das überwachte Lernen (Anwendung z.B. bei Klassifizierungsaufgaben und der Regressionsanalyse), das unüberwachte Lernen

(Anwendung z.B. bei der Mustererkennung und der Bildsegmentierung) sowie das bestärkende Lernen (Dutta 2018).

BESTÄRKENDES LERNEN

Bestärkendes Lernen (engl. Reinforcement Learning), beschreibt eine Klasse von Methoden, bei denen Programme, welche als Agenten bezeichnet werden, mit einer bekannten oder unbekanntem Umgebung in Interaktion treten. Aktionen des Agenten, welche innerhalb der Umgebung als erfolgreich einzuordnen sind, werden durch Belohnungen (engl. Rewards) honoriert. Das Ziel des Agenten ist es, die Belohnungen durch Anpassungen der Aktionen zu maximieren (Sutton u. Barto 2018).

Die zur Anwendung kommenden Theorien entstammen unter anderem dem Darwinismus, den Neurowissenschaften oder der Verhaltenspsychologie (Dutta 2018).

Am Beispiel der Simulation des Fassadentestgebäudes zeigt Abbildung 5 den grundlegenden Aufbau bei der Anwendung von bestärkendem Lernen. Die Simulation repräsentiert das Umfeld, mit welchem der Agent interagiert. Die in Tabelle 1 dargestellten Eingabeparameter, welche unter anderem aus der Simulation zum Innenraumklima und zu den Beleuchtungsstärken stammen, liefern dem Agenten die Informationen über die Umwelt. Die Umwelt besitzt hierbei eine Menge von Zuständen S . Auf der Grundlage dieser Zustände kann der Agent abhängig vom Status $s_t \in S$ eine Aktion (Regelzustand) $a_t \in A(s_t)$ für die Komponenten Heizung, Kühlung, Beleuchtung und Verschattung aus den verfügbaren Aktionen auswählen. Dies führt zu einem Folgezustand $s_{t+1} \in S$, in welchem er anhand einer Bewertung des erzeugten Zustandes eine Belohnung $r_{t+1} \in R$ erhält (Frochte 2019).

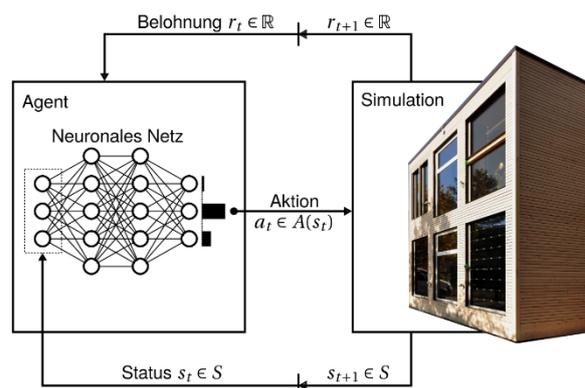


Abbildung 5: Grundlegende Architektur des bestärkenden Lernens

Aus den zur Verfügung stehenden Methoden des bestärkenden Lernens findet der Proximal Policy Optimization (PPO) Algorithmus Anwendung in der

Regelung. Dieser zeichnet sich durch einen effektiven Trainingsprozess aus und hat Mechanismen implementiert, welche für eine stabile und robuste Optimierung sorgen (Schulman et al. 2017).

Der Algorithmus wurde 2017 von der Forschungseinrichtung OpenAI vorgestellt und konnte sich seither in einer Vielzahl von Aufgabenbereichen bewähren.

Bewertungsfunktion

Für die Evaluation der durch den Agenten ausgeführten Aktionen wurde eine Bewertungsfunktion definiert, welche durch zwei Komponenten beschreiben wird. Die erste Komponente bewertet die Innenraumtemperatur in Zusammenhang mit der benötigten Heiz- oder Kühlenergie. Die zweite Komponente analysiert die Beleuchtungsstärke am Messpunkt B01 (siehe Abbildung 1) in Abhängigkeit des Energiebedarfs der Leuchtmittel. Die Summe beider Komponenten bildet die Bewertungsfunktion, welche zu jedem Zeitschritt des Simulationsdurchlaufes für den Agenten eine Belohnung ermittelt.

Für die Zusammenführung der einzelnen Komponenten ist es relevant deren Größenordnung aufeinander abzustimmen. Bei den definierten Komponenten ist jeweils eine maximale Belohnung eines Wertes von 0,2 möglich. Können beide Bedingungen simultan voll erfüllt werden, beträgt die maximale Belohnung somit 0,4. Weicht dieser Wert von den als Sollzuständen definierten Zuständen ab, hat dies eine Reduzierung des Rückgabewertes zur Folge. Um anhand der Einflussparameter Beleuchtungsstärke, Innenraumtemperatur und Energiebedarf aufeinander abgestimmte Ausgaben der Bewertungsfunktion zu erreichen, wurden Skalierungsfaktoren definiert. Diese Skalierungsfaktoren bestimmen die Gewichtung der Parameter der Bewertungsfunktion und wurden anhand eines iterativen Prozesses festgelegt.

Abbildung 6 zeigt die resultierende Belohnungskomponente in Abhängigkeit der Innenraumtemperatur (T_{01}) und des Energiebedarfs (Q) durch das Heizen oder das Kühlen. Die Innenraumtemperatur ist auf der x-Achse aufgetragen, welche sich in drei Abschnitte gliedert. Diese sind der im Innenraum einzuhaltende Temperaturbereich von 20 °C bis 26 °C sowie dessen Unter- und Überschreitung. Ein Abweichen des Sollbereichs führt zu einer Minderung der Belohnung. Diese ist definiert als der Betrag der Abweichung in °C multipliziert mit dem Faktor 0,2. Der Energiebedarf ist auf der y-Achse abgebildet. Eine Reduzierung der Belohnung findet um den Bedarf an Heiz- oder Kühlenergie in Kilowatt multipliziert mit einem Skalierungsfaktor von 0,22 statt.

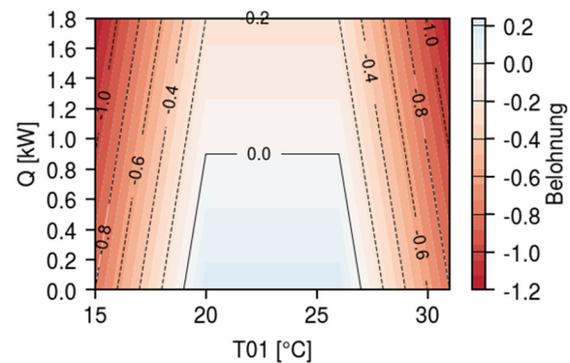


Abbildung 6: Belohnungskomponente abhängig vom Heiz- und Kühlenergiebedarf (Q) sowie der Innenraumtemperatur (T_{01})

Abbildung 7 zeigt die resultierende Belohnungskomponente in Abhängigkeit der Innenraumbeleuchtung an der Position B01 und des Energiebedarfs (Q) durch die Leuchtmittel. Die Beleuchtungsstärke an der Position B01 ist auf der x-Achse und der Energiebedarf auf der y-Achse aufgetragen. Die Bewertung der Beleuchtungsstärke teilt sich in zwei Abschnitte ein. Diese sind der Bereich unterhalb sowie oberhalb der geforderten 500 lx. Wird die Beleuchtungsstärke von 500 lx unterschritten, reduziert sich die Belohnung um den Wert der Unterschreitung in Lux dividiert durch den Skalierungsfaktor 500. Bei einer Überschreitung reduziert sich die Belohnung um den Wert der Überschreitung in Lux dividiert durch den Skalierungsfaktor 12500, jedoch nur wenn die Leuchtmittel durch den Agenten eingeschaltet wurden. Eine Reduzierung der Belohnung infolge des Energiebedarfs der Leuchtmittel findet um den Betrag des Energiebedarfs in Kilowatt, multipliziert mit einem Skalierungsfaktor von 18 statt.

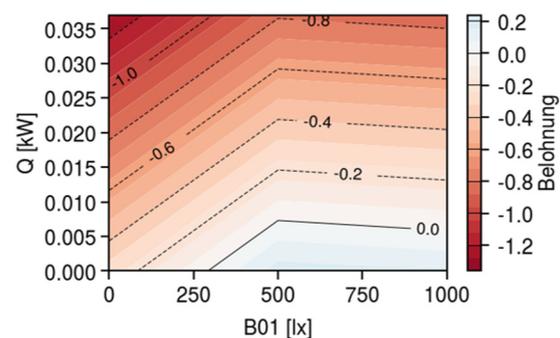


Abbildung 7: Belohnungskomponente abhängig vom Leuchtmittelenergiebedarf (Q) und der Beleuchtungsstärke an der Position B01

SIMULATION

Die für das bestärkende Lernen notwendige Interaktion mit einem Umfeld wurde durch eine bauphysikalische Simulation zum Innenraumklima sowie den Beleuchtungsstärken im Innenraum abgebildet.

Die mit dem neuronalen Netz ermittelten Vorgaben für die Regelung der Raumheizung/-kühlung, der künstlichen Beleuchtung, sowie des Transmissionszustandes der adaptiven Verglasung werden in der angewandten bauphysikalischen Simulation berücksichtigt und führen zu einer Veränderung der Raumtemperatur, der Helligkeit und des Bedarfs an Energie für die Konditionierung. Über die Beurteilung der, zu Beginn zufälligen, Regelzustände durch die Bewertungsfunktion erfolgt eine sukzessive Verbesserung des Regelverhaltens des Netzes. Das Zusammenwirken von neuronalem Netz und der bauphysikalischen Simulation folgt dem in Abbildung 5 gezeigten Schema des bestärkenden Lernens.

Um dem Agenten die Möglichkeit zu bieten, ausreichende Informationen über das Umfeld zu erlangen, ist es notwendig, den definierten Simulationsaufbau fortlaufend zu wiederholen. Die Simulationsaufrufe wurden in Längen von einem Monat eingeteilt, welche als Episode bezeichnet werden.

Verwendet wurde die Simulationssoftware TRNSYS 18, welche neben der Betrachtung des Innenraumklimas eine Berechnung der tageslichtabhängigen Beleuchtungsstärken durch die Verknüpfung mit der Software DaySIM ermöglicht.

Der Arbeitsablauf der Simulation ist in Abbildung 8 dargestellt. Dieser gliedert sich in drei wesentliche Abschnitte: das Modellieren und Definieren der Rahmenbedingungen, die Durchführung der Simulation sowie die Ausgabe und Evaluation.

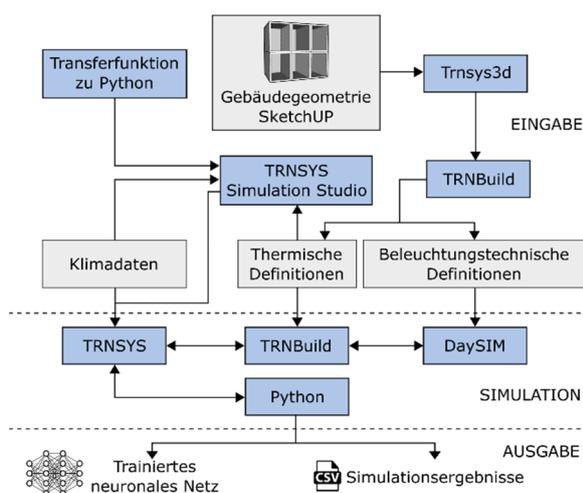


Abbildung 8: Flussdiagramm des Simulationsaufbaus

Bestandteil der Modellierung sind die Gebäudegeometrie, die Transferfunktion zu Python, die Klimadaten sowie die Definitionen thermischer und beleuchtungstechnischer Eigenschaften des modellierten Gebäudes. Diese Eigenschaften orientieren sich an den tatsächlichen Gegebenheiten des Fassadentestgebäudes. Zu den thermischen Definitionen zählen die für das Heizen und Kühlen der Räume festgelegte maximale Leistung von 1,83 kW bzw. 1,00 kW sowie Angaben zu dem Wärmedurchgangswiderstand der Wände und Decken. Beleuchtungstechnische Definitionen sind Reflexions- und Transmissionsseigenschaften der Materialien des Modells. Für die schaltbare Verglasung wurden sieben im Transmissionsgrad unterschiedliche Schaltstufen definiert. Diese sind in den thermischen und beleuchtungstechnischen Einstellungen definiert. Zudem wurde eine Luftwechselrate nach DIN EN 12831-1 von 0,5 l/h angenommen. Die für die Simulation verwendeten Klimadaten stammen von der Messdatenerfassung des Fassadentestgebäudes für das Jahr 2018.

Wird die Simulation ausgeführt, so kommunizieren die Programme TRNSYS 18, TRNBuild, DaySIM sowie Python kontinuierlich miteinander. Für den Transfer der Klimadaten und für die Kopplung der Module des Modellaufbaus sorgt TRNSYS 18, während TRNBuild für die thermische Simulation und DaySIM für die beleuchtungstechnische Auswertung verantwortlich sind. Der Einfluss der Leuchtmittelgruppen wurde auf Grundlage von Messungen der Beleuchtungsstärke am realen Objekt ermittelt und in den Simulationsablauf integriert. Über die Programmiersprache Python wurde die Regelung auf Grundlage des bestärkenden Lernens implementiert.

Zur Integration von Python stellt TRNSYS in der Version 18 zwei Komponenten zur Verfügung. Diese wurden im Vorfeld getestet, konnten jedoch den Ansprüchen des Simulationsaufbaus nicht gerecht werden. Durch die Unterstützung des Instituts für Gebäudeenergetik, Thermotechnik und Energiespeicherung der Universität Stuttgart konnte schließlich mit dem Type997 eine Transferfunktion implementiert werden, welche die Anforderungen erfüllt (Asenbeck 2019).

ERGEBNISSANALYSE UND DISKUSSION

Die nachfolgende Evaluation zeigt die Ergebnisse der Regelung nach 500 Episoden. Die Darstellung begrenzt sich auf zwei Zeitintervalle mit der Länge von jeweils einer Woche. Diese zeigen repräsentativ einen Zeitraum der Umgebungsbedingungen im Winter (01. bis 07. Januar 2018) und im Sommer (01. bis 07. Juli 2018).

Nachfolgend dargestellt sind die Messdaten zur Außentemperatur (T_{Amb}) und Globalstrahlung (PNV)

für die erste Woche im Januar und Juli 2018 (Abbildung 9 und Abbildung 10).

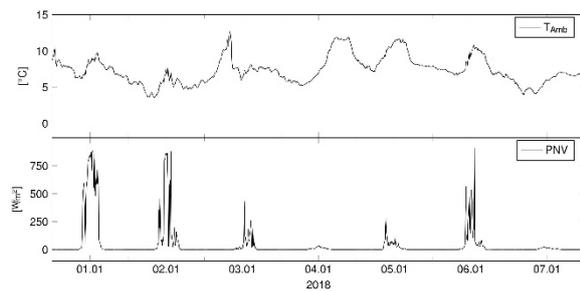


Abbildung 9: Außentemperatur und Globalstrahlung im Zeitraum vom 01. bis 07. Januar 2018

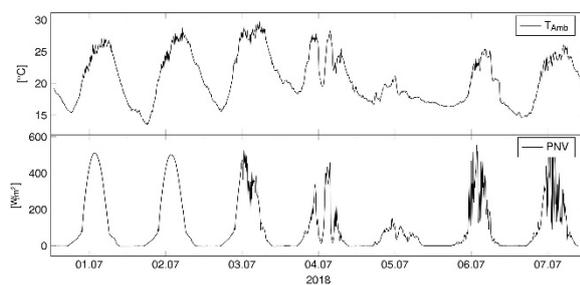


Abbildung 10: Außentemperatur und Globalstrahlung im Zeitraum vom 01. bis 07. Juli 2018

Abbildung 11 und Abbildung 12 zeigen die Resultate der vom Agenten durchgeführten Regelung für die beiden Zeitintervalle im Januar und Juli 2018. Dargestellt sind die Innenraumtemperatur (T_{01}), die Beleuchtungsstärke im Innenraum (B_{01}), die Regelung der Heizung (HT_{Setpoint}) und Kühlung (CL_{Setpoint}), die Regelung der Leuchtmittelgruppen L01 und L02, der Schaltzustand der adaptiven Verglasung (Shadestep), der gesamte benötigte Energiebedarf ($Q_{\text{HEAT}} + Q_{\text{COOL}} + Q_{\text{LIGHT}}$) und die resultierende Belohnung.

Heizung und Kühlung

Die Regelung der Heizung (HT_{Setpoint}) und Kühlung (CL_{Setpoint}) erfolgt über das Definieren der Schwellwerte der Temperatur zum Aktivieren der Heizung (bei Unterschreitung des Schwellwertes) und Kühlung (bei Überschreitung des Schwellwertes).

Die Ergebnisse der Simulation zeigen, dass der Schwellwert der Heizung, mit vereinzelt Abweichungen, auf den geforderten Mindestwert von 20 °C eingestellt ist. Dies zeigt, dass es der Regelung gelungen ist, anhand des gegebenen Umfelds eine effiziente Einstellung zu definieren. Für die Regelung des Schwellwertes der Kühlung treten hingegen Schwankungen von 23 °C bis 28 °C auf.

Künstliche Beleuchtung

Für die Regelung der künstlichen Beleuchtung können die zwei Leuchtmittelgruppen L01 und L02 über je sieben Zustände der Intensität angesteuert werden.

Bei der Steuerung des Leuchtmittels L01 ist zu erkennen, dass dieses bei geringer Globalstrahlung eingeschaltet und bei hoher Globalstrahlung ausgeschaltet wird. Damit gelingt es der Regelung, die geforderten 500 lx Beleuchtungsstärke am Messpunkt B01 einzuhalten.

Die Leuchtmittelgruppe L02 wurde hingegen durch die Regelung dauerhaft ausgeschaltet. Nachvollziehbar ist dies bei der Betrachtung der Beleuchtungsstärkenverteilung und des Energiebedarfs der Leuchtmittelgruppen. Bei maximaler Beleuchtungsstärke aller Leuchtmittel liegt der Beitrag der Leuchtmittelgruppe L02 auf den für die Bewertung herangezogenen Messpunkt B01 gerade einmal bei 12 %. Mit einem Energiebedarf von 13 W benötigt die Gruppe L02 allerdings 35 % der Energie am Gesamtanteil der künstlichen Beleuchtung. Die Verwendung der Leuchtmittelgruppe L02 ist daher ineffizient für das Einhalten des Sollwertes am Messpunkt B01. Dies hat die Regelung erkannt und vermeidet daher das Zuschalten der Leuchtmittelgruppe L02.

Adaptive Verglasung

Die adaptive Verglasung bietet die Möglichkeit, durch eine stufenweise Einstellung der Transmission sowohl auf die belichtungstechnischen als auch thermischen Anforderungen im Innenraum Einfluss zu nehmen.

Bei Betrachtung der Regelung der adaptiven Verglasung ist feststellbar, dass die Schaltstufe sowohl im Januar als auch im Juli vermehrt auf den Wert Null geschaltet wird, was einer maximalen Transmission entspricht. Hierdurch lässt sich die Notwendigkeit der Benutzung der Leuchtmittel reduzieren.

Beeinflusst wird dieses Resultat durch die unterschiedliche Einflussnahme des Schaltzustandes der Verglasung auf das sichtbare Licht und die gesamte in den Raum eingetragene Strahlungsleistung. Während der Energiedurchlassgrad (g-Wert) zwischen 17,4 % bis 21,4 % liegt, kann die Transmission des sichtbaren Lichts (T_{vis}) zwischen 3,4 % bis 26,4 % variieren (Haase u. Husser 2018). Infolgedessen steht der Regelung für die Beeinflussung der Innenraumtemperatur ein Schalhub beim g-Wert von 4,0 % zur Verfügung, während die Beeinflussung des sichtbaren Lichtes einen Schalhub beim Lichtdurchgang von 23,0 % aufweist. Eine Einflussnahme auf die belichtungsabhängigen Parameter ist somit deutlich größer als die auf die Innenraumtemperatur bzw. die Energieeinträge durch die Verglasung.

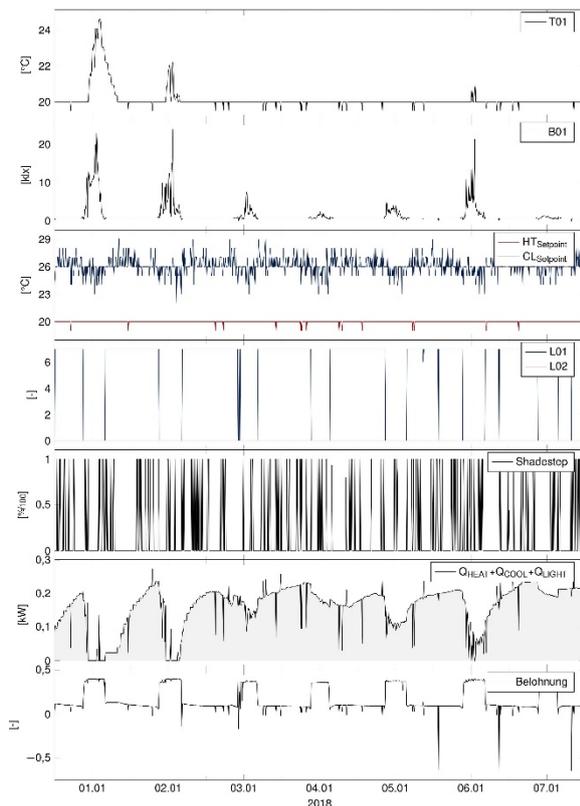


Abbildung 11: Regelung nach 500 Episoden, für den Zeitraum vom 01. bis 07. Januar 2018

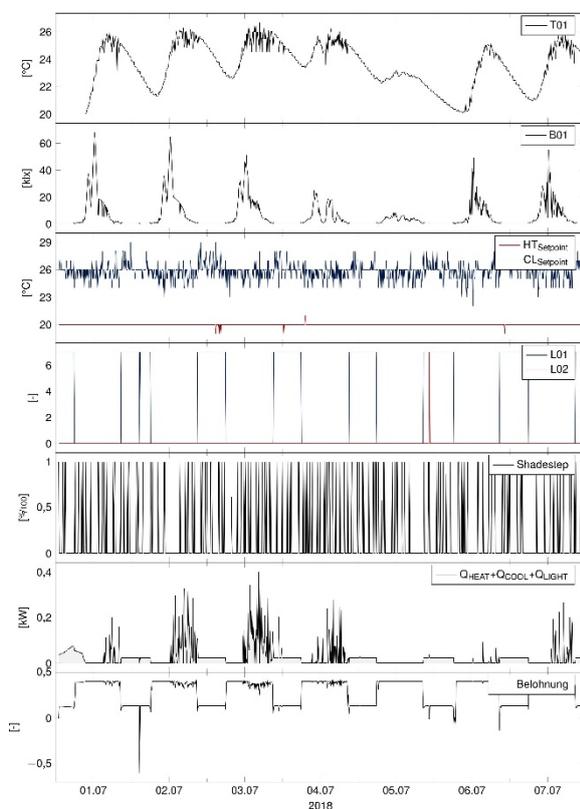


Abbildung 12: Regelung nach 500 Episoden, für den Zeitraum vom 01. bis 07. Juli 2018

Generalisierung

Das in Abbildung 13 dargestellte Zeitintervall, vom 01. bis 07. Januar 2019, befindet sich außerhalb der für das Einlernen des neuronalen Netzes verwendeten Klimadaten. Die Anwendung der erlernten Regelung auf einen unbekanntensatz soll aufzeigen, ob das neuronale Netz eine verallgemeinerte Repräsentation der Regelung erlernt hat.

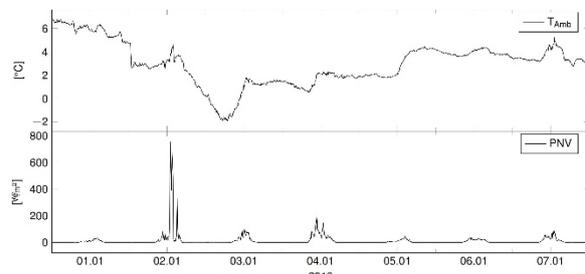


Abbildung 13: Außentemperatur und Globalstrahlung im Zeitraum vom 01. bis 07. Januar 2019

Bei Betrachtung der in Abbildung 14 dargestellten Ergebnisse der Regelung ist zu erkennen, dass die Schwellwerte der Heizung und Kühlung sowie die Steuerung der Beleuchtung und der Verschattung in gleichem Maße wie bei den zuvor betrachteten Zeitintervallen im Januar und Juli 2018 ausgeführt werden. Somit kann gezeigt werden, dass die erlernte Strategie nicht nur auf den in der Simulation verwendeten Klimadatensatz anwendbar ist, sondern im Rahmen der Untersuchung einer generalisierten Regelung entspricht.

Für den Einsatz der entwickelten Regelung unter realen Bedingungen werden jedoch noch weitere Untersuchungen benötigt, um die Zuverlässigkeit der Regelzustände zu erhöhen und den Lernprozess zu verkürzen. Für die Planung von Raum- und Gebäuderegungen könnte diese Technik jedoch bereits als effizientes Werkzeug eingesetzt werden, um komplexe Zusammenhänge der Systeme zu erkennen.

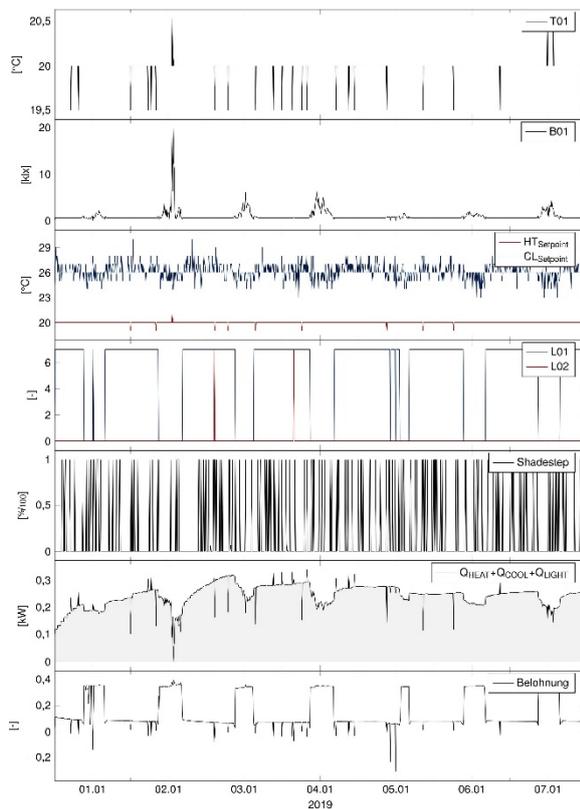


Abbildung 13: Regelung nach 500 Episoden, für den Zeitraum vom 01. bis 07. Januar 2019

ZUSAMMENFASSUNG

Um den steigenden Anforderungen an Raum- und Gebäuderegulungen gerecht zu werden, wird in diesem Beitrag eine sich selbst konditionierende Raumregelung präsentiert, welche möglichst viele Einflussparameter berücksichtigt.

Die Anforderungen an die Raumregelung waren das energieeffiziente Einhalten einer Beleuchtungsstärke von mindestens 500 lx an einem definierten Messpunkt und einer Innenraumtemperatur von 20 °C bis 26 °C. Der Einfluss auf das Innenraumklima und die Beleuchtungsstärke im Innenraum konnte durch die Regelung einer adaptiven Verglasung, der künstlichen Beleuchtung sowie der Heizung und Kühlung erfolgen.

Anwendung in der Regelung finden Methoden des bestärkenden Lernens unter Einbindung eines künstlichen neuronalen Netzes. Bestärkendes Lernen zeichnet sich durch Interaktionen mit einem Umfeld aus, welche die Lernprozesse der belebten Natur nachbilden. Als Umfeld diente dem Algorithmus eine Simulation zum Raumklima und der Innenraumbeleuchtung eines Referenzgebäudes. Anhand von Interaktionen mit der Simulation erfährt die Regelung in Abhängigkeit der Beleuchtungsstärke und Temperatur im Innenraum sowie deren Energiebedarf eine Bewertung. Diese Bewertung ermöglicht der Regelung eine sukzessive Anpassung und Optimierung des Regelverhaltens.

Anhand der Simulation konnte gezeigt werden, dass eine Regelung auf Grundlage von Methoden des bestärkenden Lernens in der Lage ist, einen Raum auf eine geforderte Temperatur und Beleuchtungsstärke wirkungsvoll zu regeln. Eine besondere Effizienz zeigte die Steuerung der künstlichen Beleuchtung durch das Deaktivieren ineffizienter Leuchtmittel zum Einhalten der Anforderungen.

LITERATUR

- Asenbeck, S., 2019. Quickstart Guide for the Trnsys-Python-Interface Type997 and TrnysysPy.py, Universität Stuttgart.
- DIN EN 12464-1, 2011. Licht und Beleuchtung – Beleuchtung von Arbeitsstätten, Teil 1: Arbeitsstätten in Innenräumen.
- DIN EN 12831-1, 2017. Energetische Bewertung von Gebäuden – Verfahren zur Berechnung der Norm-Heizlast, Teil 1: Raumheizlast, Modul M3-3.
- Dutta, S., 2018. Reinforcement Learning with TensorFlow. Packt Publishing, Birmingham.
- Ertel, W., 2016. Grundkurs Künstliche Intelligenz. 4., überarbeitete Auflage, Springer Vieweg, Wiesbaden.
- Frochte, J., 2019. Maschinelles Lernen: Grundlagen und Algorithmen in Python. 2., aktualisierte Auflage, Hanser Verlag, München.
- Haase, W. und Husser, M., 2018. Adaptive Verglasungssysteme: Einsatzbereiche, energetische und tageslichttechnische Evaluierung, Regelungsstrategien. Abschlussbericht, Forschungsinitiative Zukunft Bau, Fraunhofer IRB Verlag, Stuttgart.
- Kalmbach, S., 2019. Entwicklung, Implementierung und Evaluation eines über Reinforcement Learning trainierten künstlichen neuronalen Netzes zur Raumkonditionierung, Masterarbeit, Universität Stuttgart.
- Schulman, J. et al., 2017. Proximal Policy Optimization Algorithms, arXiv:1707.06347v2 [cs.LG].
- Sutton, R. S. und Barto, A. G., 2018. Reinforcement learning: an introduction. 2nd edition, MIT Press, Cambridge, Mass.