



HLK-Infrastruktur in der Nest-Unit Umar in Dübendorf.

Prädiktive Raumklima- regelung mit KI

IoT-basierter Prototyp | Der Betrieb von Heiz- und Kühlsystemen in Wohngebäuden hat grossen Einfluss auf die Umwelt sowie das Portemonnaie. Prädiktive Raumklima-Regelung mit Hilfe von künstlicher Intelligenz ermöglicht einen effizienteren Betrieb und einen höheren Komfort. Mit IoT-fähiger Hardware lässt sich das Konzept kostengünstig als Retrofitlösung umsetzen.

BENJAMIN HUBER

Der Gebäudebereich ist für über einen Drittel des primären Energieverbrauchs weltweit verantwortlich. Er liegt damit noch vor dem Industrie- und dem Mobilitätssektor. In industrialisierten Ländern wird rund die Hälfte dieser Energie für das Heizen, Lüften und die Klimatisierung (HLK) aufgewendet.[1] Entsprechend würde eine Verbesserung der Energieeffizienz von Heiz- und Kühlsystemen die Treibhausgasemissionen signifikant reduzieren und hätte folglich einen positiven Einfluss auf den Klima-

wandel. Gleichzeitig verbringen Menschen bis zu 90% ihrer Lebenszeit in Gebäuden.[2] Ein marktfähiger Verbesserungsansatz muss deshalb berücksichtigen, dass die Energieeinsparungen nicht auf Kosten des Komforts gehen dürfen. Kostspielige Modernisierungen der Gebäudehülle oder des Heiz-/Kühlsystems sind übliche Massnahmen, um diesen Ansprüchen gerecht zu werden. Im Gegensatz dazu kann der Betrieb von Heiz-/Kühlsystemen relativ kostengünstig optimiert werden, indem die vorhandene

Steuerung durch ein intelligentes Regelsystem ersetzt oder erweitert wird.

Modellprädiktive Regelung als Goldstandard

In den meisten Wohngebäuden werden heute noch immer sehr einfache Regler wie z. B. Raum- oder Heizkörperthermostate verwendet. Diese sind zwar sehr robust und relativ kostengünstig, berücksichtigen aber wichtige Informationen wie beispielsweise Wetterprognosen nicht. Deshalb und durch

ihr reaktives Verhalten büssen sie an Performance ein.

Die Modellprädiktive Regelung (engl. Model Predictive Control, MPC) ist ein moderner, proaktiver Ansatz zur Energie- und Raumklimaoptimierung in Gebäuden. Mit Hilfe eines mathematischen Modells des Gebäudes und Wetterprognosen werden die optimalen Heiz-/Kühlleistungen unter Berücksichtigung von Komfortbedingungen über einen definierten Zeithorizont berechnet (**Bild 1**). Um veränderten Wetterprognosen und äusseren Einflüssen gerecht zu werden, wird die optimale Heiz-/Kühlleistung in regelmässigen Zeitabständen neu berechnet.

Diverse Studien haben bereits gezeigt, dass mit MPC der Energieverbrauch in Gebäuden deutlich reduziert werden kann.[3, 4] Trotzdem ist der Einsatz von MPC in Wohngebäuden noch nicht verbreitet. Als Hauptgrund werden die Kosten, welche mit der Entwicklung von mathematischen Gebäudemodellen einhergehen, genannt. [1, 5] Anders als zum Beispiel bei Autos, die in grossen Mengen identisch gefertigt werden, sind die meisten Gebäude unterschiedlich im Hinblick auf die Konstruktion, den Grundriss, die geografische Lage und die Nutzung. Dies hat zur Folge, dass auch die jeweiligen Gebäudemodelle unterschiedliche Parameter besitzen und deshalb individuell bestimmt werden müssen. Dieser Prozess der Modellidentifikation ist dementsprechend mit relativ grossem Aufwand verbunden und erfordert Expertenwissen, was MPC für Wohngebäude momentan ökonomisch gesehen unattraktiv macht.[1]

Digitalisierung als Türöffner

Durch die Digitalisierung in der Gebäudetechnik ergeben sich nun aber Chancen für MPC. Elektronische Komponenten wie Temperatur-, Feuchtigkeits- oder Helligkeitssensoren, aber auch Mikrocontroller werden immer kostengünstiger. Mit Hilfe von IoT-Lösungen können die anfallenden Daten unkompliziert in einer Datenbank gespeichert und ausgewertet werden. Die Informationen, welche aus diesen Daten gewonnen werden können, ermöglichen wiederum die Optimierung des Gebäudebetriebs. Dabei ist ein möglicher Ansatz, die Vorteile von MPC und Machine Learning zu vereinen. Anstelle von mathematischen

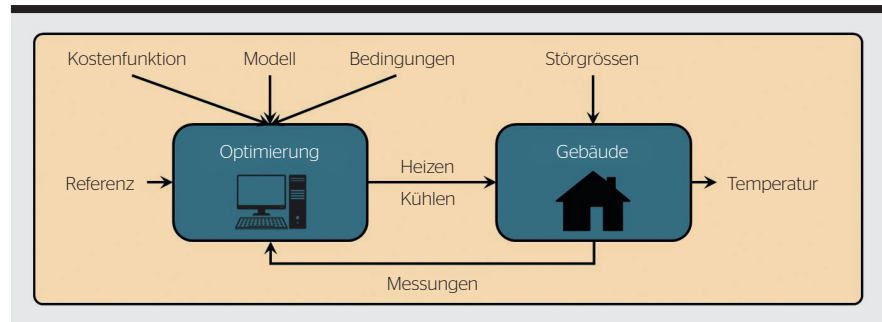


Bild 1 Prinzip der Modellprädiktiven Regelung.



Bild 2 Wohneinheit Umar im Nest an der Empa Dübendorf.

Gebäudemodellen, basierend auf physikalischen Naturgesetzen, können sogenannte Black-Box-Modelle, welche mittels Machine-Learning-Algorithmen und historischen Daten trainiert wurden, verwendet werden. Dieser Ansatz wird datengetriebenes MPC, Data Predictive Control oder kurz DPC genannt. Der mit der Modellidentifikation verbundene Aufwand kann dadurch im Vergleich zu klassischen Methoden deutlich reduziert werden. Einerseits, weil das Modellieren einfach automatisierbar ist und deshalb keine Experten mehr für diese Aufgabe eingesetzt werden müssen. Andererseits lernt das System durch regelmässiges Re-Training der Modelle die Veränderungen des Gebäudes, seien diese konstruktiv oder betrieblich, selbstständig.

Data Predictive Control im Praxistest

Die Energy-Hub-Gruppe der Empa hat einen DPC-Ansatz in der Wohneinheit Umar (Urban Mining & Recycling) im

Nest in Dübendorf (**Bild 2**) implementiert und getestet. Hierzu konnten die Aktoren im Gebäude über die vorhandene OPC-UA-Plattform angesteuert werden.[6] In den Experimenten wurden im DPC-Algorithmus Random Forests kombiniert mit linearen Modellen verwendet.[7, 8] Diese zwei Machine-Learning-Modelle, welche das thermische Verhalten des Gebäudes prognostizieren, lernten ihre Parameter ausschliesslich aus historischen Daten von rund einem Jahr. Der DPC-Algorithmus plante jeweils sechs Stunden voraus, wobei die Optimierung alle 30 Minuten neu durchgeführt wurde.[7]

Um die Performance des Reglers zu analysieren, wurde in einem von zwei vergleichbaren Räumen der DPC-Algorithmus sowie gleichzeitig im anderen Raum ein konventioneller Thermostat mit Hysterese getestet. In verschiedenen Experimenten wurde in dem Zimmer, das mit dem DPC-Algorithmus geregelt wurde, rund 25% weniger Energie benötigt als im konventionell

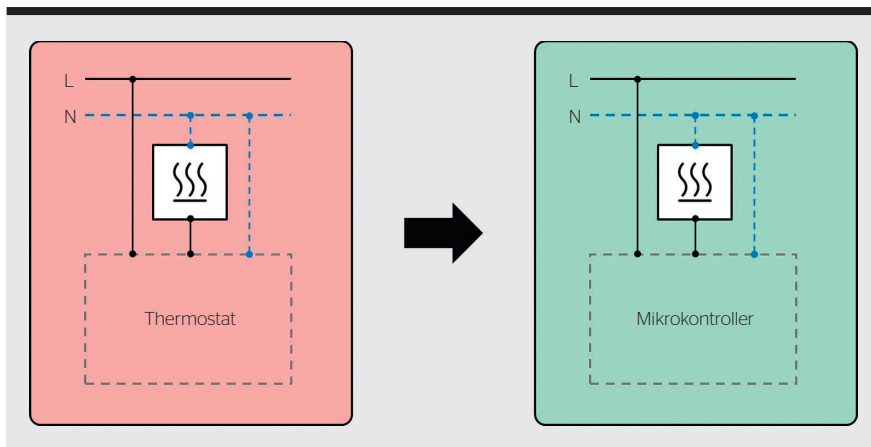


Bild 3 Die Retrofittung für herkömmliche Raumthermostate nutzt dieselben Anschlüsse.

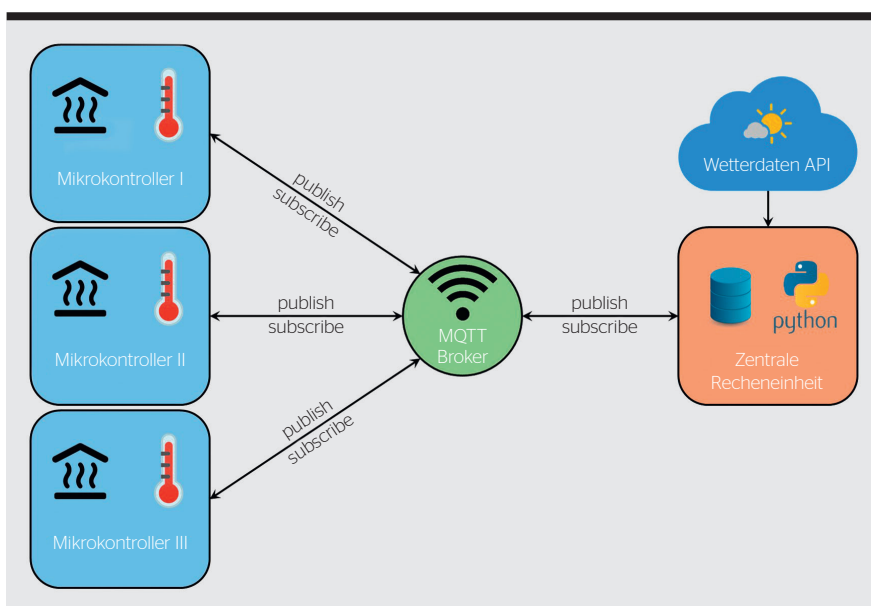


Bild 4 Kommunikation mit dem MQTT-Protokoll.

betrieben. Trotz den signifikanten Energieeinsparungen wurden die Komfortbedingungen, gemessen in Dauer und Höhe der Temperaturdifferenz zu einem Temperaturreferenzband, sogar um 72% weniger verletzt.[7] Der Modellierungsansatz mit Random Forests und linearen Modellen hat gegenüber typischerweise nicht-linearen Machine-Learning-Modellen (z. B. herkömmliche, künstliche neuronale Netze) den grossen Vorteil, dass das Optimierungsproblem im DPC-Algorithmus linear oder zumindest konvex ist. Dies bedeutet, dass mit den heute verfügbaren Algorithmen immer eine optimale Lösung garantiert werden kann. Ausserdem wird beträchtlich weniger Rechenkapazität benötigt als bei nicht-konvexen Optimierungsproblemen, welche oft mit Brute-Force-

Methoden gelöst werden müssen. Im Nest können die Experimente von einem Cloud-Server oder einer Desktop-Hardware gesteuert werden, weshalb die Rechen- und Speicherkapazitäten keine limitierenden Faktoren sind. Soll die Technologie jedoch den Transfer in die Industrie schaffen, so muss diese auch auf kostengünstiger Hardware umsetzbar sein.

Prototyp als erster Schritt des Technologietransfers

Deshalb wurde im nächsten Schritt der DPC-Algorithmus statt auf einer Desktop-Hardware auf Mikrocontrollern implementiert mit dem Ziel, eine kostengünstige Retrofittung für die Einzelraumregelung zu erlangen. Bei diesem Konzept werden herkömmliche Raumthermostate, welche über eine

einfache Hysterese regeln, mit einem IoT-fähigen Mikrocontroller ersetzt. Durch einen AC/DC-Wandler wird der Mikrocontroller mit 5 V vom Netz versorgt (**Bild 3**).

Mit dem Mikrocontroller sind ein Temperatur- und ein Feuchtigkeitssensor verbunden. Deren Messergebnisse werden periodisch über das Machine-to-Machine (M2M) Kommunikationsprotokoll Message-Queuing-Telemetry-Transport (MQTT) und WLAN an eine zentrale Recheneinheit gesendet. Hier wurde ein Raspberry Pi3 als Recheneinheit verwendet, weil er mit einem 1,2-GHz-Quad-Core-Prozessor und 1 GB RAM über ausreichend Rechenleistung und Arbeitsspeicher verfügt. Vorstellbar wäre an dieser Stelle aber auch eine Cloud-Lösung. Auf der zentralen Recheneinheit wurden neben allen Sensordaten von den jeweiligen Mikrocontrollern auch die aktuellen Wetterdaten sowie Wetterprognosen über eine Python API abgefragt. Somit verfügte die zentrale Recheneinheit über alle relevanten Informationen, die für den DPC-Algorithmus benötigt werden. Dieser ist damit imstande, für den definierten Zeithorizont die optimalen Heiz-/Kühlleistungen zu berechnen. Optimal bedeutet hier, eine vorgegebene Kostenfunktion zu minimieren, welche Heiz-/Kühlenergie und Komfort berücksichtigt. Folglich wird der Energieverbrauch minimiert, ohne an Wohlfühlkomfort einzubüssen. Die so berechneten Ventilstellungen der Heizverteilung werden wiederum über das MQTT-Protokoll an die Mikrocontroller kommuniziert. Hierfür sind die jeweiligen Mikrocontroller auf die spezifischen Topics subscribed und können über Halbleiter-Relais (SSR) die Stellantriebe ansteuern. **Bild 4** zeigt illustrativ die verschiedenen Kommunikationswege.

Die Retrofittung konnte erfolgreich in einer weiteren Nest-Unit, dem DFAB House, umgesetzt werden. Während der Entwicklung des Prototyps wurde zudem Verbesserungspotenzial beim DPC-Algorithmus identifiziert, welches die Performance des Reglers zusätzlich steigern könnte.

Nächster Schritt: den Technologietransfer meistern

Neben der Weiterentwicklung und der Optimierung des Algorithmus sowie der Hardware besteht die grösste Hürde

darin, den Technologietransfer erfolgreich zu gestalten. Damit dies gelingen kann, muss einerseits die Robustheit des Systems gewährleistet sein und andererseits die Vorzüge von DPC gegenüber anderen Technologien offensichtlich werden. Den zweiten Punkt zu erfüllen, ist im aktuellen Marktumfeld eine enorme Herausforderung, weil es eine Vielzahl von neuen, digitalisierten Thermostatlösungen gibt. Jede davon hat ihre Vorteile, die mit gutem Marketing angepriesen werden. Für den Endkunden sind diese Produkte jedoch schwer unterscheidbar, weil oft verschiedene Benchmarks verwendet werden, um die Performance zu quantifizieren. Die grösste Chance, den Technologietransfer erfolgreich zu

meistern, besteht deshalb darin, zusammen mit einem oder mehreren etablierten Industriepartnern ein marktfähiges Produkt zu entwickeln.

Referenzen

- [1] D. Sturzenegger, D. Gyalistras, M. Morari, R. S. Smith, «Model Predictive Climate Control of a Swiss Office Building: Implementation, Results, and Cost - Benefit Analysis», IEEE Trans. Control Syst. Technol., vol. 24, no. 1, pp. 1-12, 2016, doi: 10.1109/TCST.2015.2415411.
- [2] J. Y. Park, Z. Nagy, «Comprehensive analysis of the relationship between thermal comfort and building control research - A data-driven literature review», Renew. Sustain. Energy Rev., vol. 82, no. April 2017, pp. 2664-2679, Feb. 2018, doi: 10.1016/j.rser.2017.09.102.
- [3] F. Oldewurtel et al., «Use of model predictive control and weather forecasts for energy efficient building climate control», Energy Build., vol. 45, pp. 15-27, 2012, doi: 10.1016/j.enbuild.2011.09.022.
- [4] J. Široký, F. Oldewurtel, J. Cigler, S. Prívvara, «Experimental analysis of model predictive control for an energy efficient building heating system», vol. 88, pp. 3079-3087, 2011, doi: 10.1016/j.apenergy.2011.03.009.
- [5] A. Jain, F. Smarra, M. Behl, R. Mangharam, «Data-Driven Model Predictive Control with Regression Trees - An Application to Building Energy Management», vol. 2, no. 1, pp. 1-21, 2018.
- [6] R. Fricker, «Flexible Forschung mit flexibler Kommunikation», bulletin.ch, 2018. www.bulletin.ch/de/news-detail/flexible-forschung-mit-flexibler-kommunikation.html.
- [7] F. Bünning, B. Huber, P. Heer, A. AbouDonia, J. Lygeros, «Experimental demonstration of data predictive control for energy optimization and thermal comfort in buildings», Energy Build., vol. 211, 2020, doi: 10.1016/j.enbuild.2020.109792.
- [8] F. Smarra, A. Jain, T. De Rubens, D. Ambrosini, A. D. Innocenzo, R. Mangharam, «Data-driven model predictive control using random forests for building energy optimization and climate control», Appl. Energy, vol. 226, no. January, pp. 1252-1272, 2018, doi: 10.1016/j.apenergy.2018.02.126.



Autor

Benjamin Huber ist wissenschaftlicher Mitarbeiter an der Empa.
→ Empa, 8600 Dübendorf
→ benjamin.huber@empa.ch

RÉSUMÉ

Contrôle prédictif de la température ambiante grâce à l'IA

Prototype basé sur l'Internet des objets

L'utilisation des systèmes de chauffage et de climatisation des bâtiments résidentiels exerce un impact majeur sur l'environnement ainsi que sur le portemonnaie: le secteur du bâtiment est en effet responsable de plus d'un tiers de la consommation d'énergie primaire au niveau mondial. Afin de réduire la consommation des bâtiments résidentiels, il est possible d'utiliser un réglage prédictif de la climatisation reposant sur l'intelligence artificielle, qui offre non seulement un fonctionnement plus efficace, mais aussi un plus grand confort.

Le groupe Energy Hub de l'Empa a mis en œuvre et testé une telle approche prédictive, dénommée Data Predictive Control (DPC), dans une unité résidentielle du bâtiment expérimental Nest, à Dübendorf. Des modèles d'apprentissage automatique (ici de type random forest combinés à des modèles linéaires) ont été entraînés avec des données his-

toriques récoltées sur une durée d'un an afin de pouvoir reproduire le comportement thermique du bâtiment dans l'algorithme DPC. Ce dernier a planifié le comportement du bâtiment chaque fois avec six heures d'avance, tout en réalisant de nouvelles optimisations toutes les 30 minutes.

Par rapport à un thermostat classique avec hystérésis, l'algorithme DPC a permis de réduire la consommation d'énergie d'environ 25% au cours de diverses expériences. Malgré les importantes économies d'énergie, les conditions de confort ont été mieux respectées: les écarts de température par rapport à une plage de référence, mesurés en fonction de leur durée et de l'importance de la différence, ont même pu être réduits de 72%. Dans l'objectif d'obtenir une solution rétrofit rentable pour le réglage individuel des pièces, ce concept a ensuite été transposé avec succès sur des microcontrôleurs compatibles avec l'Internet des objets. **no**



NFO Sinus Frequenzumrichter für höchste Personensicherheit

Einfache Installation

- Keine geschirmten Kabel, Filter oder Drosseln nötig
- Unbegrenzte Motorkabellänge

Sichere Technologie

- Keine Lager- und Erdströme
- Zuverlässiger Betrieb am FI möglich

Leiser Betrieb

- Keine elektromagnetischen Störungen
- Keine Schaltgeräusche

Mehr erfahren
elektron.ch/nfo

ELEKTRON
power on