

PHYSIKGELEITETES LERNEN THERMISCHER GEBÄUEDYNAMIK

Noah KRZYWON^{(*)1}, Regina HEMM², Peter WIDHALM³

Inhalt

Die zunehmende Einspeisung erneuerbarer Energien verschiebt die Herausforderungen von Energiesystemen: Die Fähigkeit, Lasten zeitlich flexibel anzupassen, gewinnt gegenüber einer reinen Verbrauchsreduktion zunehmend an Bedeutung [1]. Gebäude können hierzu einen wesentlichen Beitrag leisten, indem ihre thermische Trägheit gezielt zur Lastverschiebung genutzt wird [2]. Um diese Flexibilität in der Praxis erschließen zu können, werden Modelle benötigt, die trotz begrenzter Gebäudeinformationen und eingeschränkter Datenlage sowohl die Heizlast zuverlässig vorhersagen als auch die durch veränderte Heizlast verursachten Temperaturänderungen präzise abbilden können [3].

Ein wesentliches methodisches Problem ergibt sich dabei aus den üblicherweise verfügbaren Gebäudedaten: Innenraumtemperaturen werden meist in einem eng geregelten Komfortbereich gehalten, sodass nur eine geringe Dynamik beobachtet werden kann und Abhängigkeiten von wesentlichen Einflussgrößen, wie etwa der zugeführten Heizleistung, nur schwer lernbar sind [4].

Rein datengetriebene Modelle haben unter diesen Bedingungen Schwierigkeiten: Ohne physikalisches Vorwissen benötigen sie hinreichend variierende Systemzustände, die genügend Information enthalten, um belastbare Zusammenhänge zu erlernen. Bei unzureichender Anregung können die abgeleiteten Modelle zwar die Trainingsdaten reproduzieren, liefern unter zuvor nicht beobachteten Kombinationen von Einflussgrößen jedoch häufig physikalisch inkonsistente Prognosen [5].

Physikalisch strukturierte Ansätze wie RC-Modelle begegnen diesem Problem, indem sie Energiebilanzgleichungen als Modellgrundlage nutzen. Obwohl sie von ihrer induktiven Struktur profitieren, sind ihre Parameter unter realen Messbedingungen nicht immer eindeutig identifizierbar; zusätzlich beeinträchtigen unbeobachtete Einflüsse wie interne Wärmegewinne durch Personen und Geräte oder nutzerinduzierte Lüftung die Parameteridentifikation und damit auch die Prognosequalität [6].

Physics-Informed Neural Networks (PINNs) kombinieren RC-Modellstrukturen mit der Flexibilität neuronaler Netze und adressieren damit sowohl den geringen Informationsgehalt der Daten als auch die Herausforderungen der Parameteridentifikation. Durch die Einbettung der Energiebilanzgleichungen in die Verlustfunktion des neuronalen Netzes werden RC-Parameter und Netzgewichte gemeinsam optimiert. Das Modell lernt eine glatte Approximation der Temperaturverläufe, während die physikalische Verlustfunktion sicherstellt, dass die vorhergesagten Temperaturänderungen den thermodynamischen Gesetzmäßigkeiten entsprechen [7]. Dadurch entstehen Modelle, die sowohl datenbasiert plausibel als auch physikalisch konsistent sind [8].

Methodik

Um die Eignung von PINNs für die Vorhersage der Innenraumtemperatur zu untersuchen, werden drei Modellklassen miteinander verglichen: (i) ein datengetriebenes Long Short-Term Memory (LSTM)-Modell, (ii) ein klassisches RC-Modell und (iii) ein PINN.

Als Referenz dienen dynamische Gebäudesimulationen in IDA ICE, welche Innenraumtemperaturen und Heiz-/Kühlleistungen unter einem historischen Wetterjahr bereitstellen.

Die RC-Parameter werden mittels numerischer Integration und nichtlinearer Least-Squares-Optimierung bestimmt, wobei die Parameter so angepasst werden, dass die simulierten Innenraumtemperaturen die in der Referenzsimulation berechneten Verläufe möglichst genau reproduzieren. Beim PINN erfolgt die Optimierung von RC-Parametern und Netzgewichten simultan, wobei die RC-Differenzialgleichungen als Regularisierungsterm in die Verlustfunktion eingehen. Das LSTM dient als flexible Black-Box-Referenz ohne physikalische Struktur. Bewertet werden sowohl die

¹ AIT Austrian Institute of Technology GmbH, Giefinggasse 4, 1210 Wien, noah.krzywon@ait.ac.at

² AIT Austrian Institute of Technology GmbH, Giefinggasse 4, 1210 Wien, regina.hemm@ait.ac.at

³ AIT Austrian Institute of Technology GmbH, Giefinggasse 4, 1210 Wien, peter.widhalm@ait.ac.at

Vorhersagegüte als auch die Dateneffizienz, also die Fähigkeit der Modelle, auch bei begrenzten Trainingsdaten robuste und physikalisch konsistente Vorhersagen zu liefern.

Ergebnisse

Bei einem Trainingsdatenumfang von 10 Tagen und gleichbleibender Temperaturregelung mit konstantem Sollwert und Hysterese erreichen alle Modelle ähnliche Genauigkeiten (Abbildung 1, linker Plot). Bei veränderter Temperaturregelung zeigen sich deutliche Unterschiede: Während das LSTM-Modell in diesem Szenario seine Vorhersagefähigkeit einbüßt, bleiben das RC-Modell und das PINN stabil (Abbildung 1, rechter Plot). Insgesamt zeigt das PINN in beiden Szenarien die höchste Genauigkeit, insbesondere dann, wenn die Eingangsbedingungen von den Trainingsdaten abweichen.

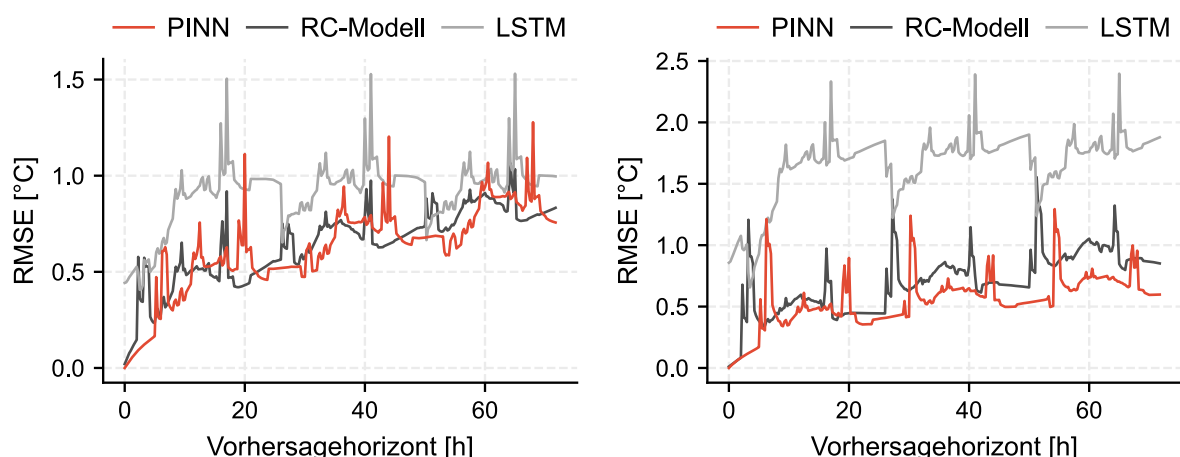


Abbildung 1: Der Vorhersagefehler (RMSE) der unterschiedlichen Modelle gegen den Prognosehorizont bei gleichbleibendem Temperatur-Sollwert und Hysterese (linke Abbildung) und bei verändertem Temperatur-Sollwert und Hysterese (rechte Abbildung).

Referenzen

- [1] W. Heitkoetter, B. U. Schyska, D. Schmidt, W. Medjroubi, T. Vogt, und C. Agert, „Assessment of the regionalised demand response potential in Germany using an open source tool and dataset“, *Adv. Appl. Energy*, Bd. 1, S. 100001, Feb. 2021, doi: 10.1016/j.adapen.2020.100001.
- [2] J. Lind, E. Möllerström, H. Averfalk, und F. Ottermo, „Energy flexibility using the thermal mass of residential buildings“, *Energy Build.*, Bd. 301, S. 113698, Dez. 2023, doi: 10.1016/j.enbuild.2023.113698.
- [3] Z. Luo u. a., „Demand Flexibility of Residential Buildings: Definitions, Flexible Loads, and Quantification Methods“, *Engineering*, Bd. 16, S. 123–140, Sep. 2022, doi: 10.1016/j.eng.2022.01.010.
- [4] R. Serasinghe, N. Long, und J. D. Clark, „Parameter identification methods for low-order gray box building energy models: A critical review“, *Energy Build.*, Bd. 311, S. 114123, Mai 2024, doi: 10.1016/j.enbuild.2024.114123.
- [5] L. Di Natale, B. Svetozarevic, P. Heer, und C. N. Jones, „Physically Consistent Neural Networks for building thermal modeling: Theory and analysis“, *Appl. Energy*, Bd. 325, S. 119806, Nov. 2022, doi: 10.1016/j.apenergy.2022.119806.
- [6] H. Harb, N. Boyanov, L. Hernandez, R. Streblow, und D. Müller, „Development and validation of grey-box models for forecasting the thermal response of occupied buildings“, *Energy Build.*, Bd. 117, S. 199–207, Apr. 2016, doi: 10.1016/j.enbuild.2016.02.021.
- [7] G. Gokhale, B. Claessens, und C. Develder, „Physics informed neural networks for control oriented thermal modeling of buildings“, *Appl. Energy*, Bd. 314, S. 118852, Mai 2022, doi: 10.1016/j.apenergy.2022.118852.
- [8] M. Raissi, P. Perdikaris, und G. E. Karniadakis, „Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations“, *J. Comput. Phys.*, Bd. 378, S. 686–707, Feb. 2019, doi: 10.1016/j.jcp.2018.10.045.