

PHYSIKGELEITETES LERNEN THERMISCHER GEBÄUDEDYNAMIK

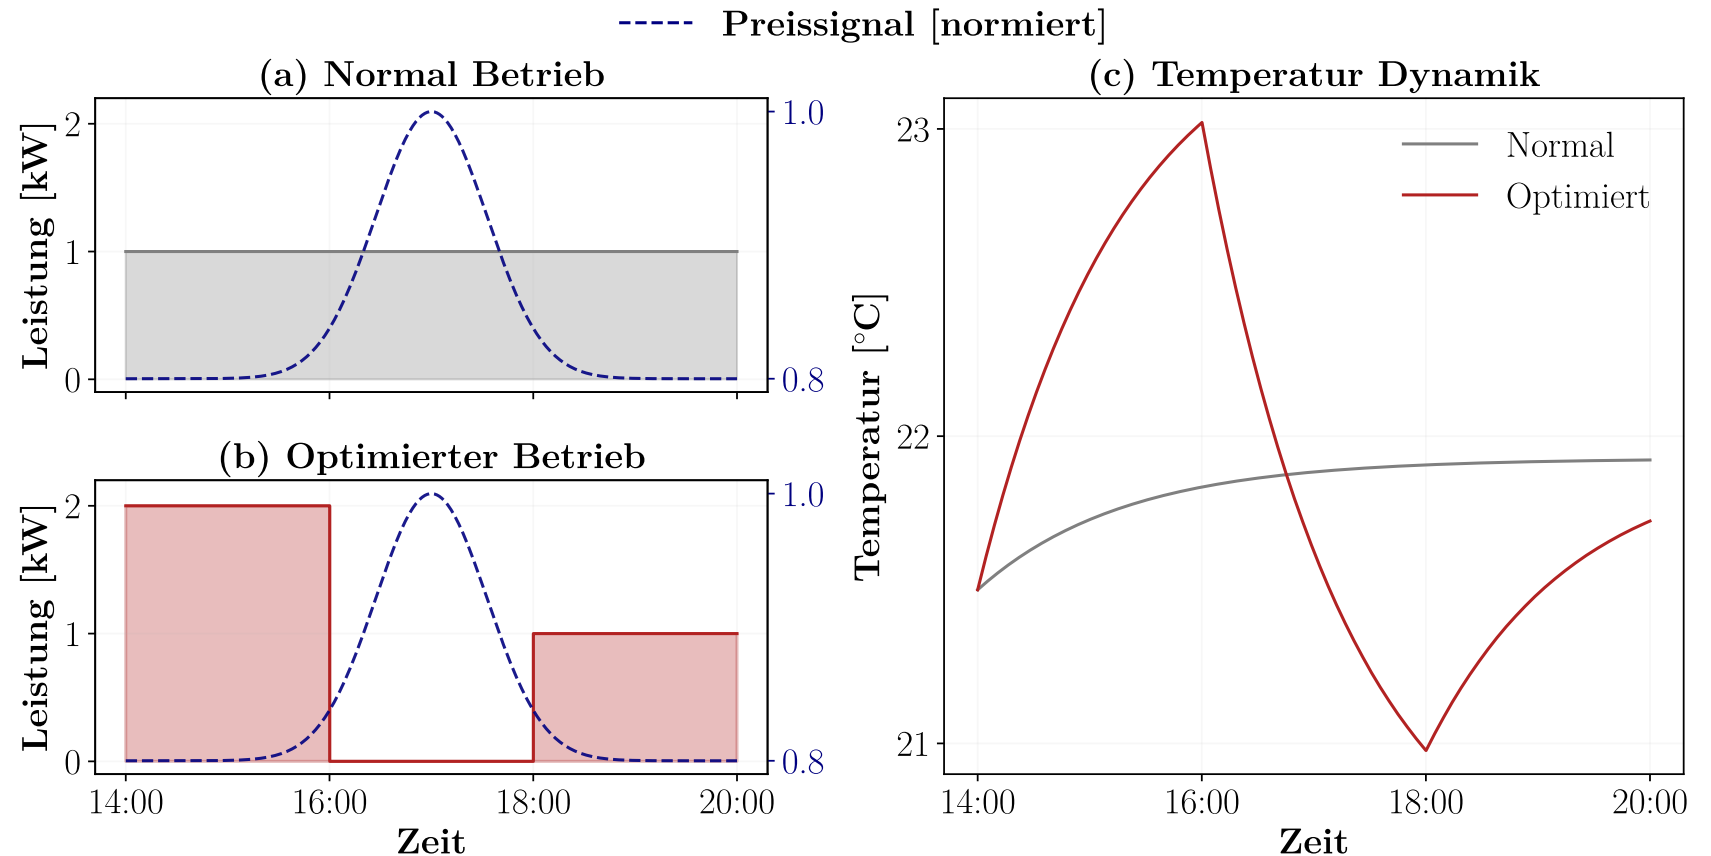
Ein physik-informierter Ansatz für robuste Temperaturvorhersagen bei wenig Daten

Noah Krzywon



Flexibilitätsoptimierung profitiert von thermischen Gebäudemodellen

- Lastverschiebung
- Thermische Masse als Energiespeicher
- Thermisches Gebäudemodell zur Ermittlung potenzieller Lösungen



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.

J. Dragoňa u. a., „All you need to know about model predictive control for buildings“, Annu. Rev. Control, Bd. 50, S. 190–232, Jan. 2020, doi: 10.1016/j.arcontrol.2020.09.001.

Verschiedene Ansätze kommen mit unterschiedlichen Vor- und Nachteilen

White Box

- ✓ Interpretierbarkeit & Generalisierungsfähigkeit
- ✗ Rechen- & Kalibrierungsaufwand

Black Box

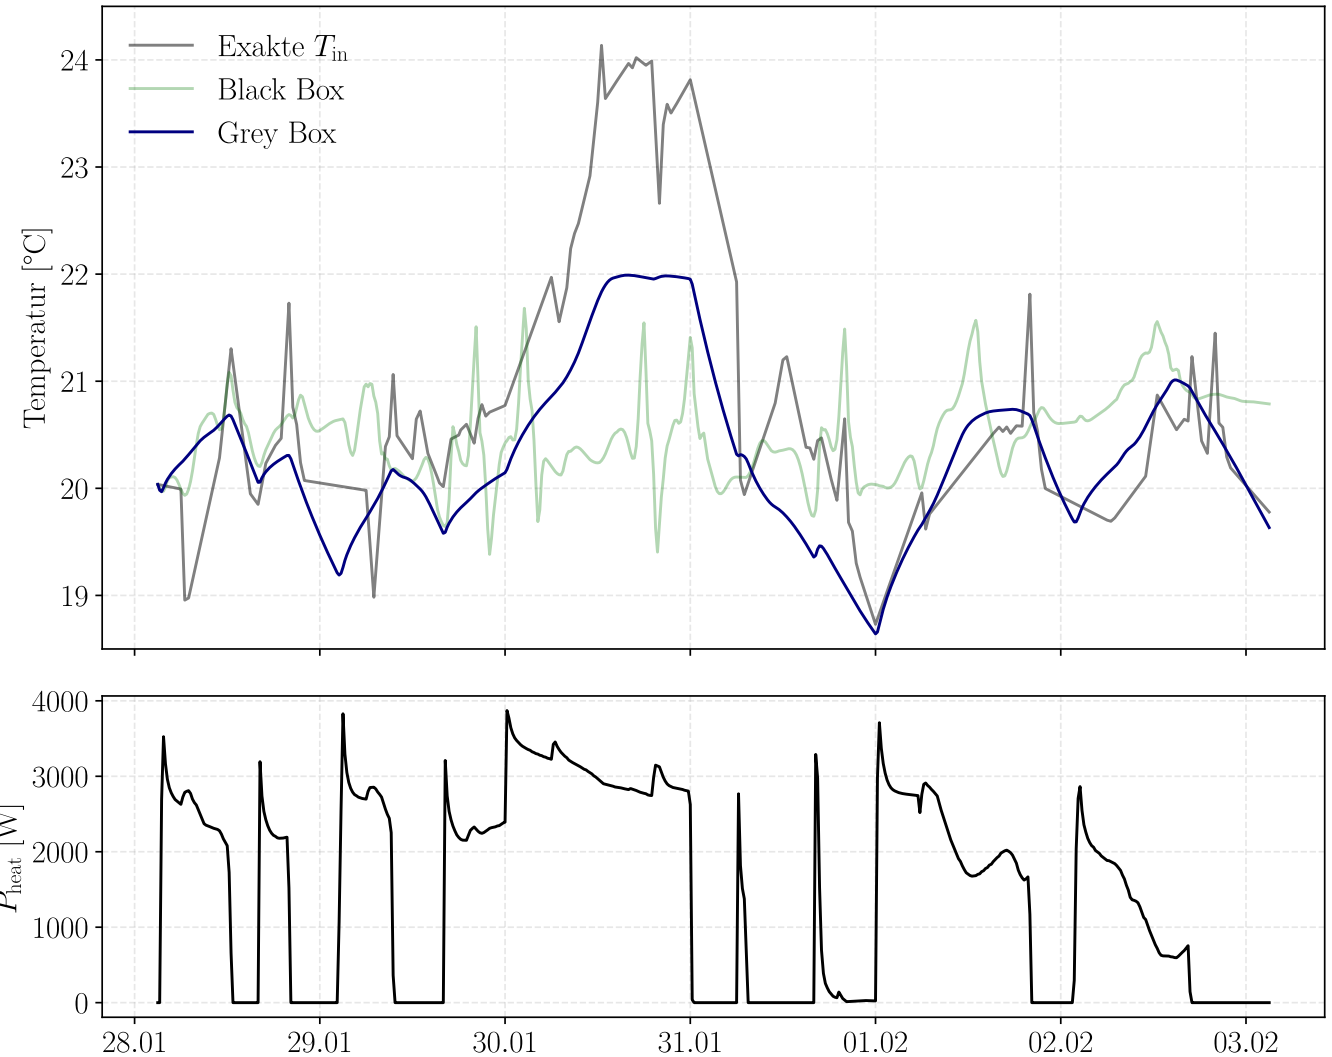
- ✓ Kalibrierungsaufwand
- ✗ Generalisierungsfähigkeit & Datenbedarf

Grey Box

- ✓ Kalibrierungsaufwand & Generalisierungsfähigkeit
- ✗ Vorhersagegenauigkeit bei wenig Daten

Black Box folgt Daten – Grey Box folgt Physik

- **Black Box:**
 - folgt Korrelationen
 - reagiert nicht plausibel
- **Grey Box:**
 - physikalisch konsistente Dynamik
 - plausible Reaktionen
 - Vorhersagegüte abhängig von Datenauswahl



J. Vivian, E. Prativiera, N. Gastaldello, und A. Zarrella, „A comparison between grey-box models and neural networks for indoor air temperature prediction in buildings“, J. Build. Eng., Bd. 84, S. 108583, Mai 2024, doi: 10.1016/j.job.2024.108583.


Evaluierung der Ansätze auf Gebäudesimulationsdaten

Trainingsdaten:

- 7 ausgewählte Tage, verteilt über ein Jahr
- Enge Komfortbereiche:
 - $20.0 \pm 1.0 \text{ °C}$, $25.0 \pm 1.0 \text{ °C}$

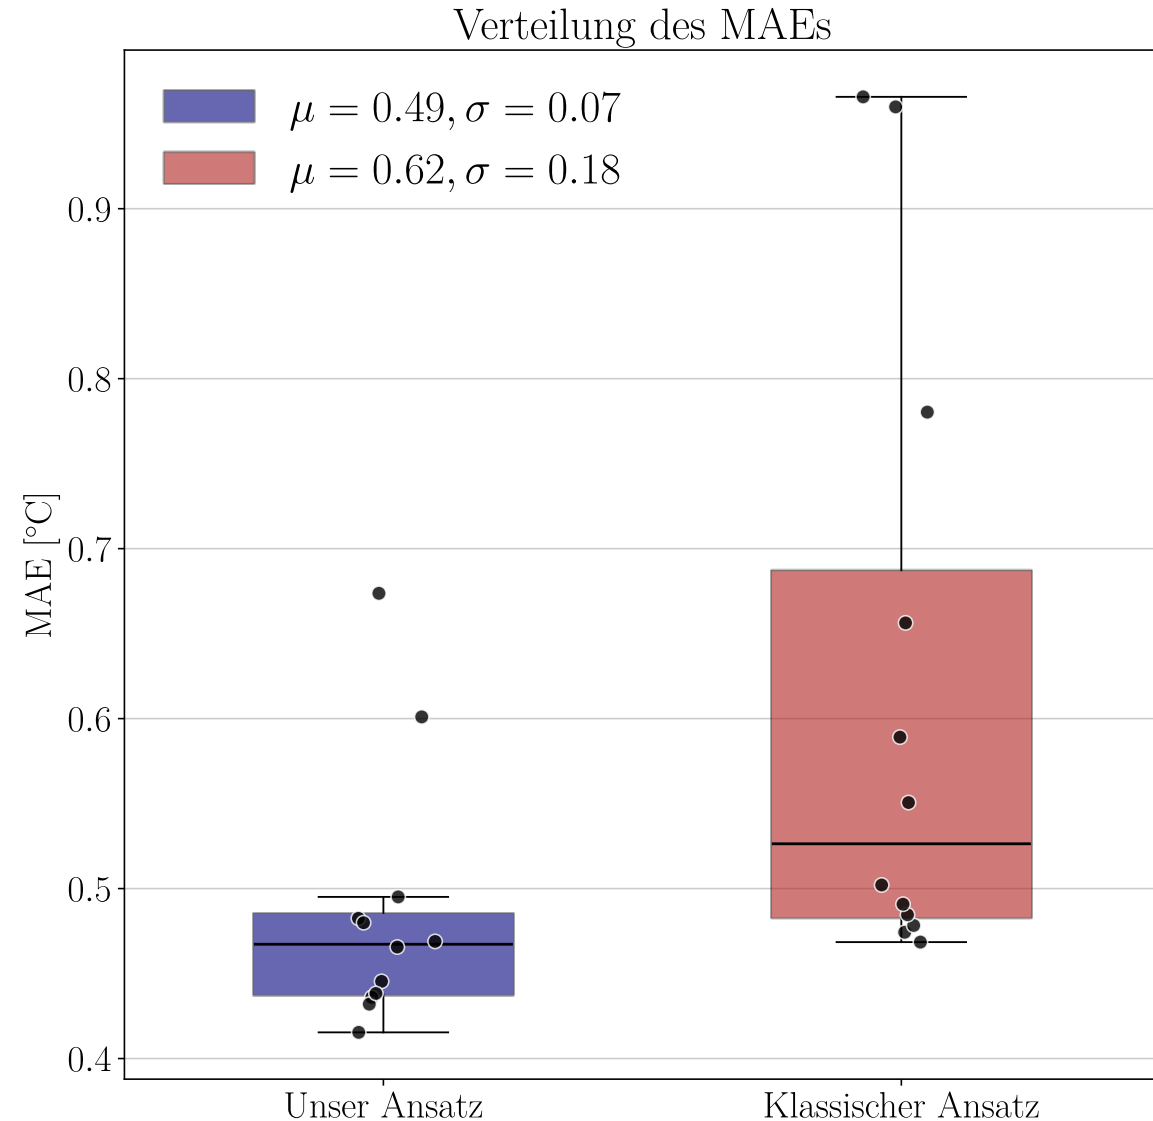
Validierungsdaten:

- 365 Tage
- Erweiterte Komfortbereiche:
 - $20.0 \pm 1.5 \text{ °C}$, $25.0 \pm 1.5 \text{ °C}$



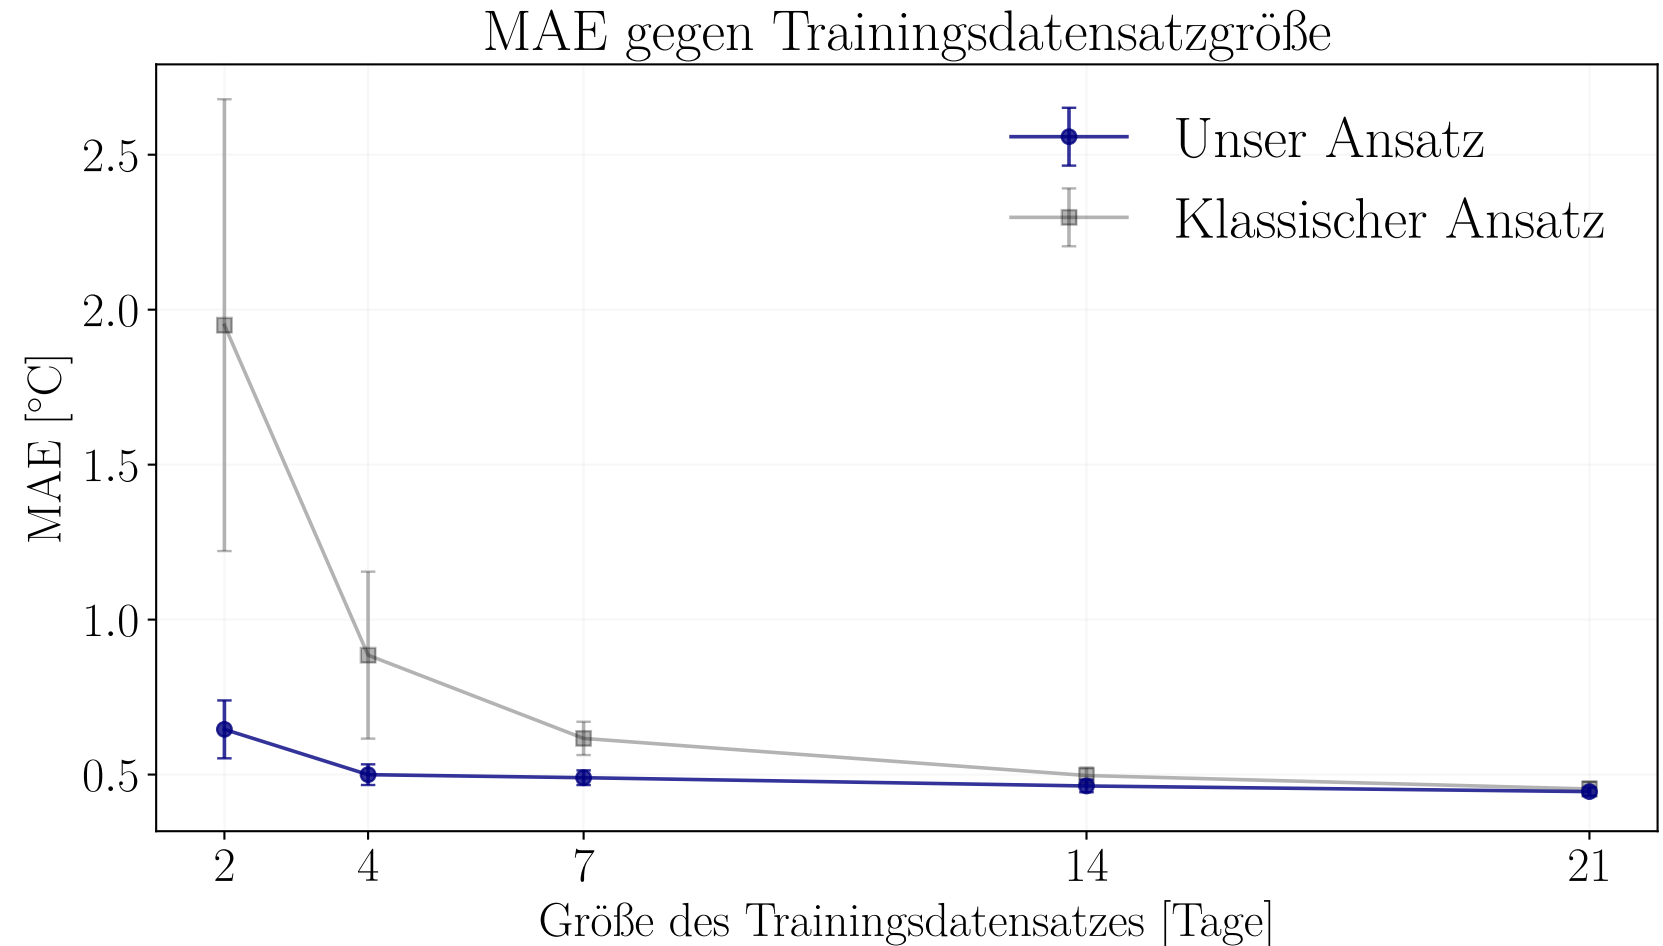
Stabiles Training trotz variierender Datenwahl

- Streuung der Fehler (MAE) misst Sensitivität
- Klassischer Ansatz:
 - Vorhersagefehler variiert stark über verschiedene Trainingsdatensätze
- Unser Ansatz:
 - Vorhersagefehler variiert kaum über verschiedene Trainingsdatensätze



Robuste Vorhersagen mit minimalen Daten

- Mittlerer Vorhersagefehler (MAE) mit Standardfehler
- Klassischer Ansatz:
 - Benötigt mehr Daten
 - Instabil gegenüber Datenauswahl
- Unser Ansatz:
 - Benötigt weniger Daten
 - Stabil gegenüber Datenauswahl



Potenziale thermischer Gebäudemodelle: Einsatzszenarien & Mehrwert

- Flexibilitätsoptimierung
 - Lastverschiebung unter Einhaltung der Komfortgrenzen
- Energieoptimierungen
 - Vorausschauendes Heizen und Kühlen durch Modellprognosen
- Surrogatmodell
 - Physikalisch konsistentes Trainingsumfeld für RL-Agenten
 - Virtuelle Testumgebung für Anpassungen am Gebäude

J. Drgoňa u. a., „All you need to know about model predictive control for buildings“, Annu. Rev. Control, Bd. 50, S. 190–232, Jan. 2020, doi: 10.1016/j.arcontrol.2020.09.001.

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.

Literaturverzeichnis

1. 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.
2. J. Drgoňa u. a., „All you need to know about model predictive control for buildings“, Annu. Rev. Control, Bd. 50, S. 190–232, Jan. 2020, doi: 10.1016/j.arcontrol.2020.09.001
3. J. Vivian, E. Prativiera, N. Gastaldello, und A. Zarrella, „A comparison between grey-box models and neural networks for indoor air temperature prediction in buildings“, J. Build. Eng., Bd. 84, S. 108583, Mai 2024, doi: 10.1016/j.jobbe.2024.108583.
4. 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.

Vielen Dank für Ihre Aufmerksamkeit!



Noah Krzywon

noah.krzywon@ait.ac.at

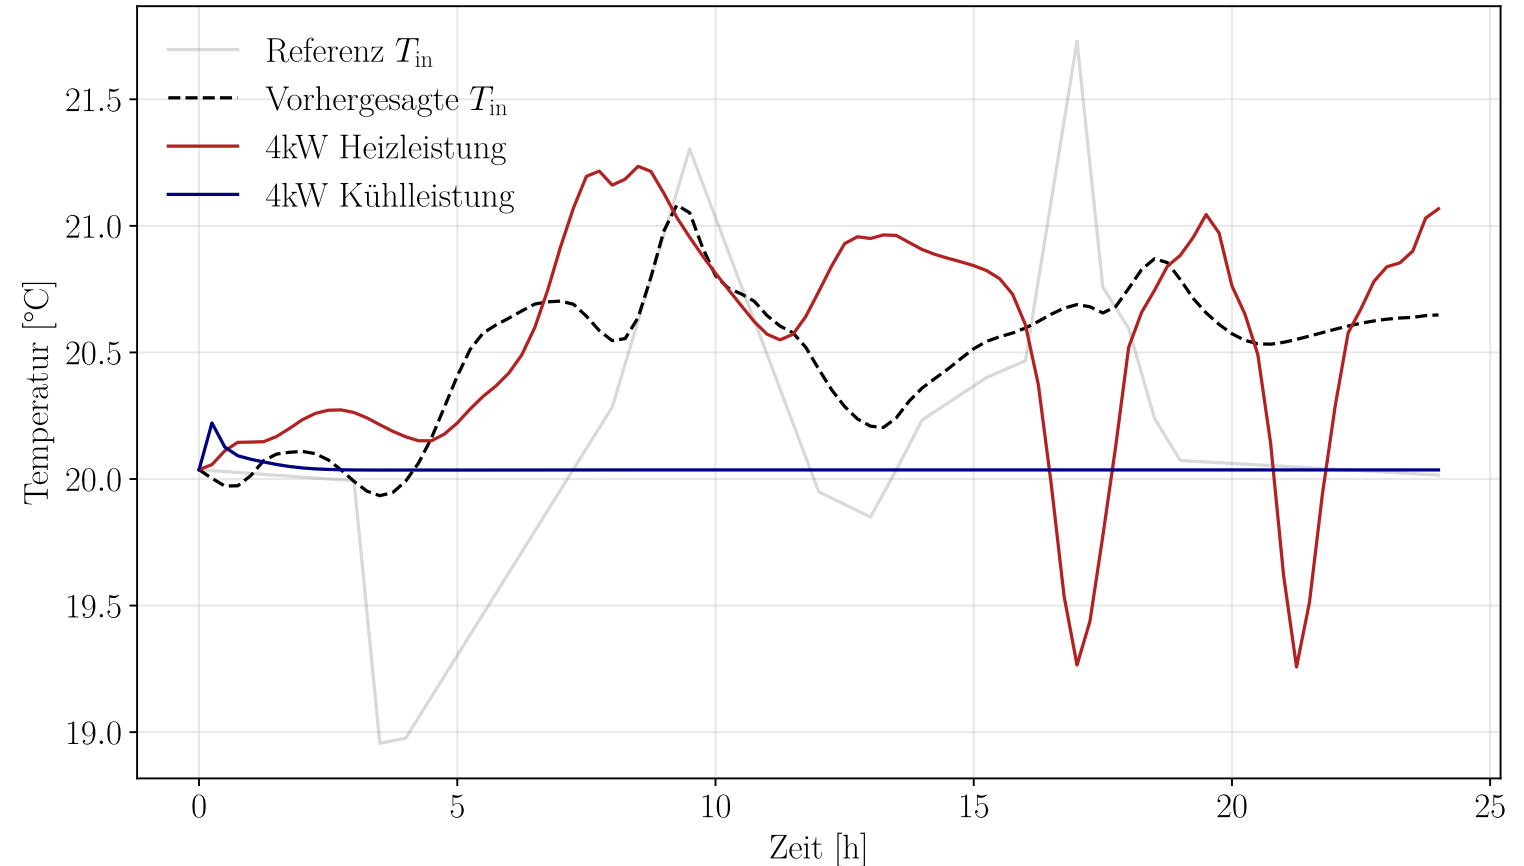
+43 676 6610520



Black-Box-Modelle lernen Korrelationen statt Physik

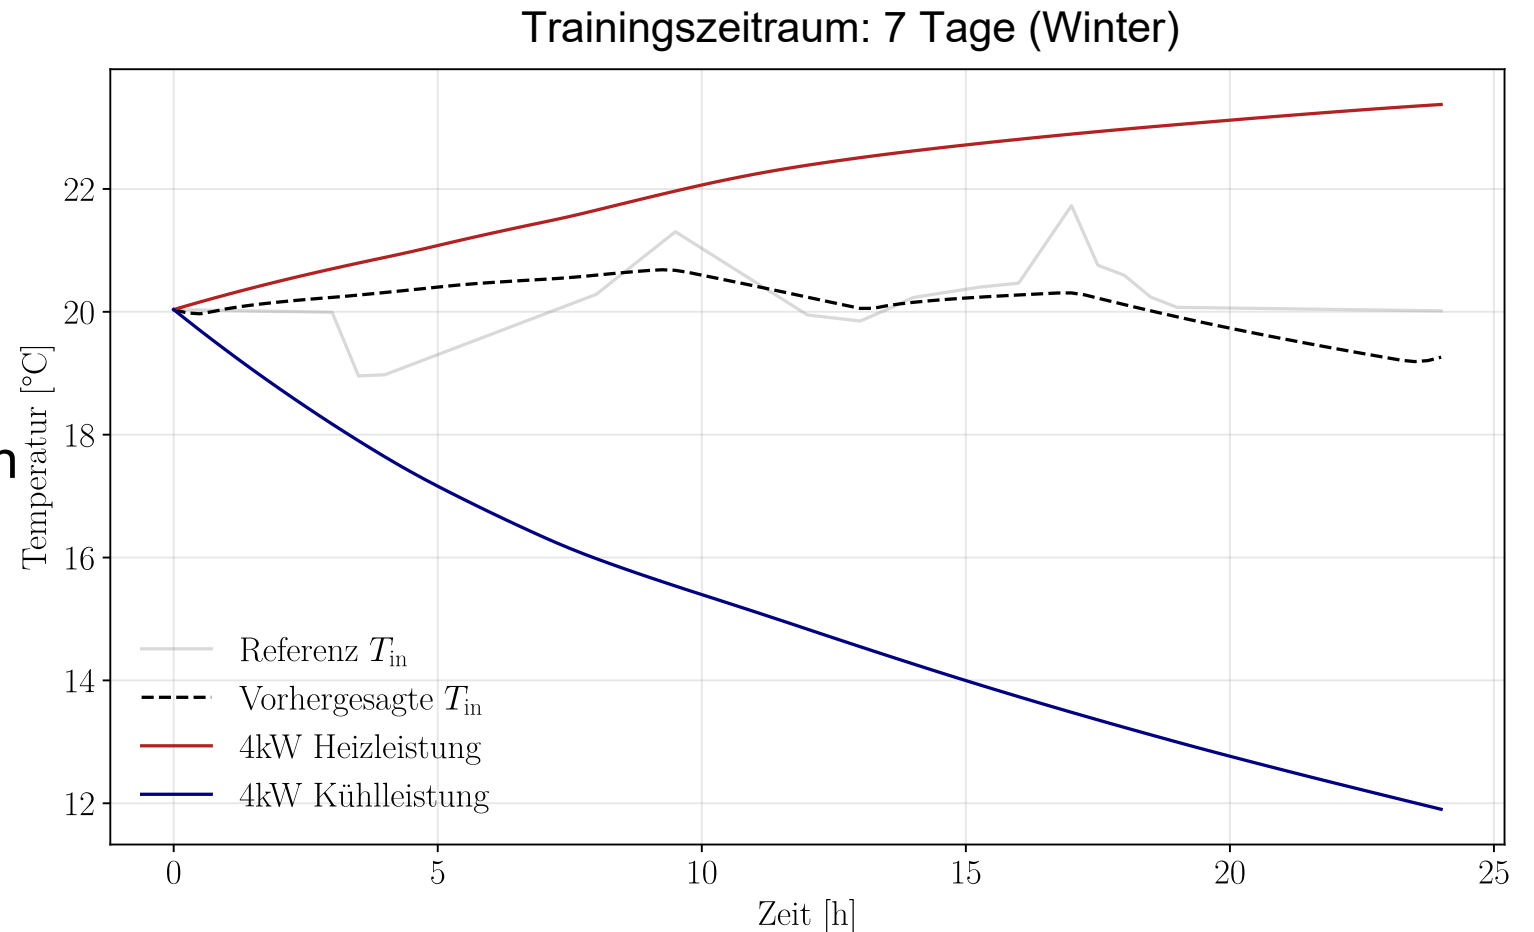
- Statistische Zusammenhänge
 - Energieerhaltungssätze nicht explizit verankert
 - Vorhersagequalität stark abhängig von der Trainingsdatenmenge
- Black-Box-Modelle verletzen bei Informationsmangel physikalische Erhaltungssätze

Trainingszeitraum: 7 Tage (Winter)




Physik mindert die Auswirkungen der Datenknappheit

- Energieerhaltungssätze explizit vorgegeben
 - Training reduziert sich auf die Schätzung von einigen Parametern
- Physikalische Struktur sichert Plausibilität auch bei wenigen Daten

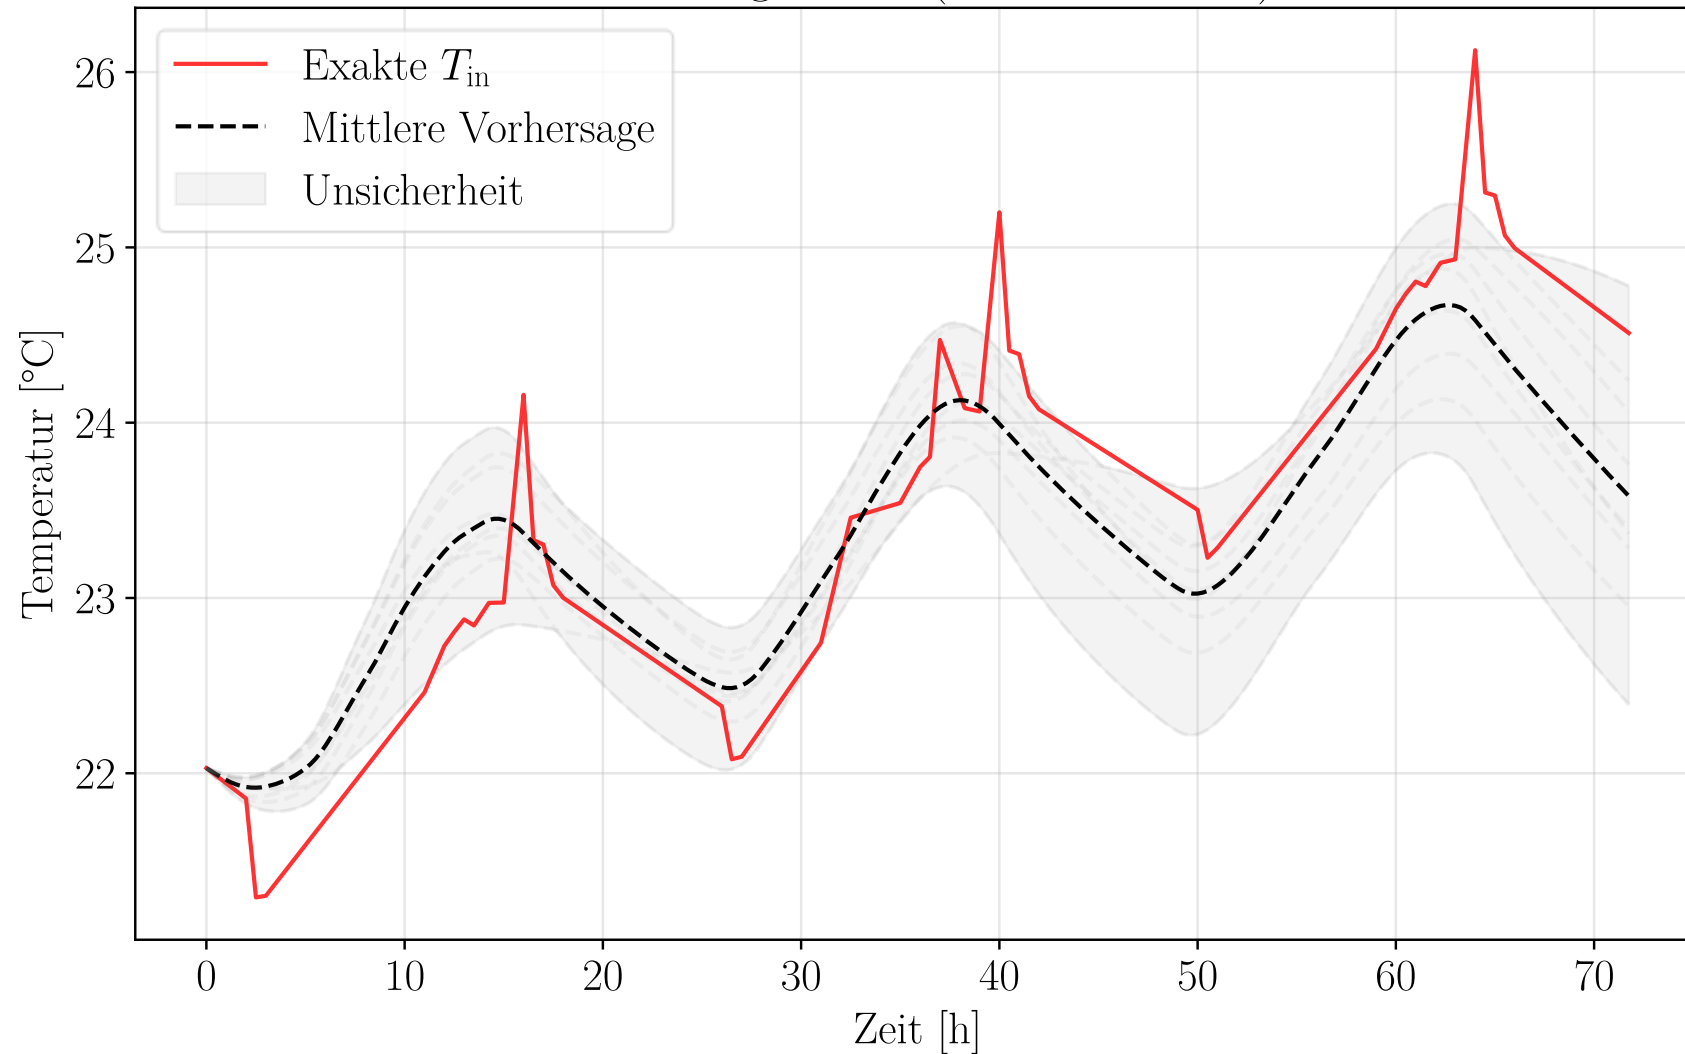


Stabile Identifikation trotz variierender Datenwahl

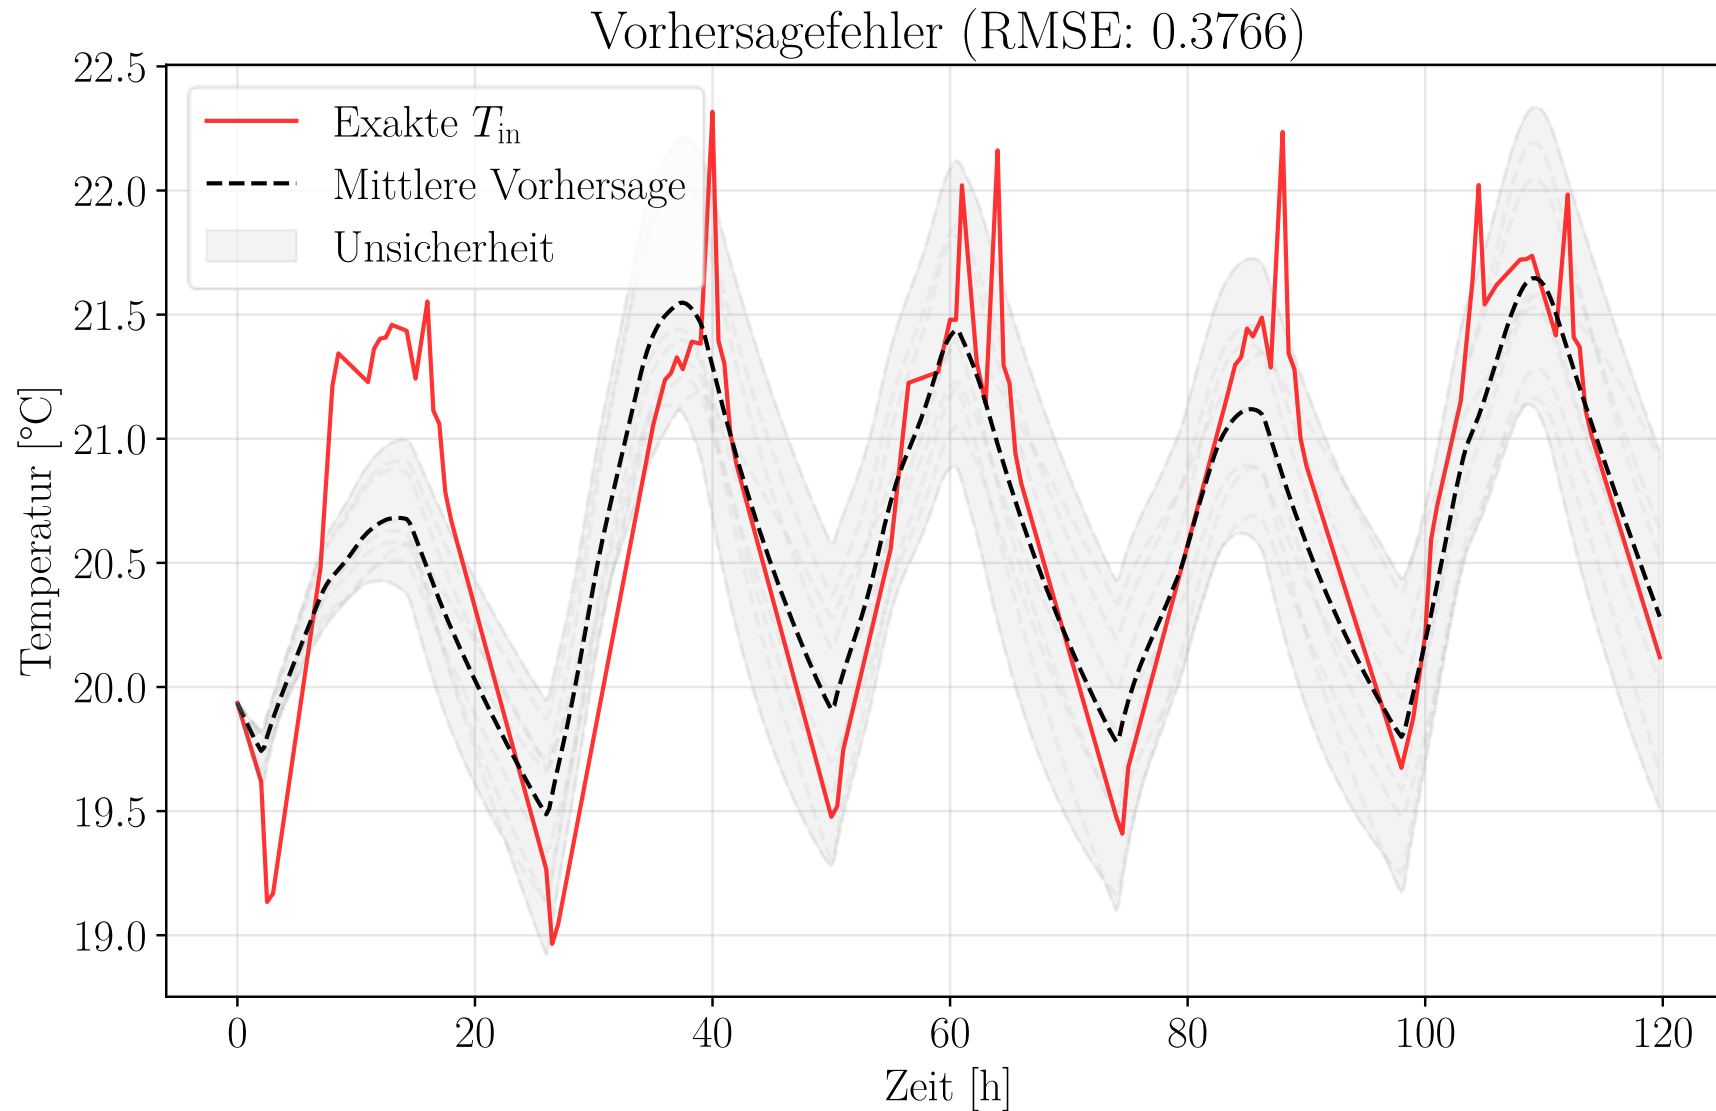


Appendix

Vorhersagefehler (RMSE: 0.4534)



Appendix



Appendix

Vorhersagefehler (RMSE: 0.3983)

