

Kalibrierung eines komplexen Fahrzeugkabinenmodells unter Verwendung eines Variational-Auto-Encoders als KI-Ersatzmodell

Dr. Thomas Koch

Raja Grizi, M.Sc.
Tobias Freund, M.Sc.
Dr. Robert Flesch

PHYMOS - Proper Hybrid Models for Smarter Vehicles

- Erzeugung skalierbarer, prädiktiver Modelle
- **hybride Ansätze** (daten- und physikbasiert) in konkreten Anwendungen
- Nutzung von vorhandenem **physikalischem Vorwissen** in dateneffizienter Weise
- Erzeugung, Entwicklung und Realisierung innovativer Produkteigenschaften in **wesentlich kürzerer Zeit**

Thema heute:

- **Verwertung** einiger Erkenntnisse & Methoden
- Vorbereitung auf **Anwendung in Kundenprojekten**
- **Workflow** für effiziente Kalibrierung von Kabinenmodellen



<https://phymos.de/>

Beteiligung XRG:

- Johannes Brunnemann
- Boris Michaelsen
- Shashidhar Mallapur
- Carsten von Ohlen
- Julius Aka (UNIA/XRG)
- Robert Flesch



Funded by
the European Union
NextGenerationEU

Supported by:



on the basis of a decision
by the German Bundestag

Förderkennzeichen: **19I20022F**

Aufgabe:

- Simulation des thermodynamischen Verhaltens einer **Kfz-Kabine**. Ermittlung der **Energiebilanz** (HVAC-Leistung) und **lokaler Temperaturen** (HVAC-Regelung)

Einsatzgebiete:


- Stand-Alone Simulationen, Co-Simulation mit anderen Teilsystemmodellen, **Gesamtfahrzeugsimulationen**

Ansatz:

- Unterteilung des Innenraums in gekoppelte **ideal vermischte Volumina** und **Wandmodelle**


Voraussetzung:

- **Effiziente Kalibrierung** der Systemparameter **an Messdaten** oder Ergebnissen bestehender CFD-Modelle



Ansatz	Computational Fluid Dynamics	Ideal Mixed Volumes
Energetische Auswertung	😊	😊
lokale Geschwindigkeiten und Temperaturen	😊	😐
Echtzeitfähigkeit	😞	😊

- » **Kurzwellige** Sonnenstrahlung
- » **Langwellige** Wärmestrahlung
- » **Konvektiver** Wärmetransport
- » **Reflexion** an Oberflächen
- » **Wärmeleitung** mehrschichtiger Wände
- » **Interne** Wärmeeinträge (Insassen)
- » **Thermische Massen**
- » Änderung der Randbedingungen durch **Fahrzeugbewegung**
- » **Kondensation** an Oberflächen
- » **Kohlendioxid**-Konzentration bei Umluftbetrieb
- » **Klimagerät**: Quelle temperierter Luft





Konstruktionsdaten für...

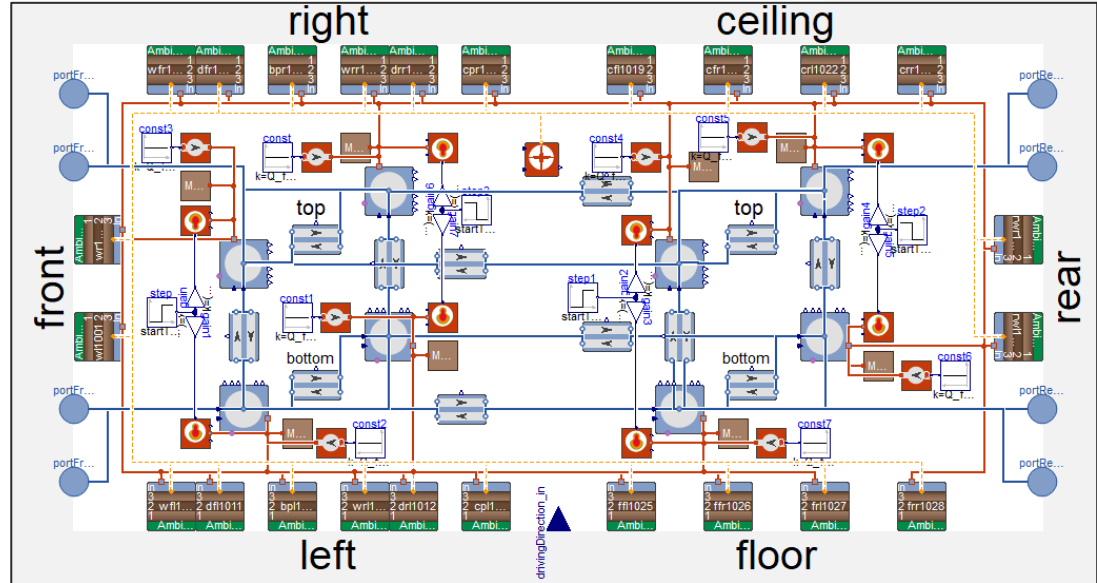
- Wandaufbau & -materialien
- Flächengrößen und -ausrichtung
- Interne Massen
- Fensterflächen
- Position Luftein- und auslässe

- Mehrere hundert Wandmodelle
- globale Abhängigkeiten
- Nichtlinearitäten

Korrekturfaktoren für...

- Konvektion intern/extern
- thermische Kapazitäten
- Luftwechselraten

20-30 Kalibrationsparameter



Bsp.: *HumanComfortLib.Zones.Automotive.Cabin1D_8Volume.CabinPartitions1D*



Klassische Teststandszenarien:

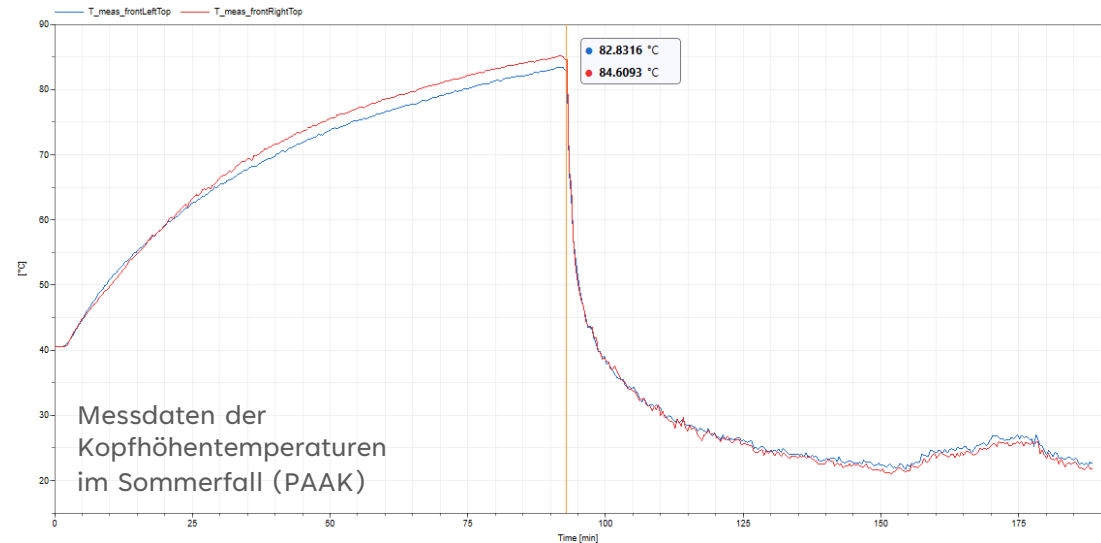


- Passive Aufheizung & aktive Kühlung
- aktive Aufheizung

Zeitabhängige Messdaten:

- Umgebung (Temperatur, Sonneneinstrahlung, Fahrgeschwindigkeit)
- eingeblasene temperierte Luftströme
- Zeitreihen $x(t)$ von Temperatursensoren

Zielvorgaben:

- fünf Temperaturen, z.B. Kopfhöhen, Fußhöhen, WSS, Auslasstemperatur
- Möglichst universelle Kalibrierung, für...
 - ... EPA/WLTP Fahrzyklen
 - ... variable Belüftungssteuerung
 - ... ähnliche Fahrzeuggeometrien



Bisher teilautomatisierte Kalibrierung:

- Erfahrungswerte/**Expertenwissen nötig** für Parameterauswahl, -abhängigkeiten, -sensitivitäten
- Messdaten durch Modell reproduzierbar?
- **Schrittweiser Prozess:** Parametercluster, z.B. für Steady-state und Dynamik
- Iterativ, unterstützt durch beaufsichtigten in-house Optimierer
- Ergebnis ist im allg. **lokales Minimum**
- u.U. **zwei Parametersets** für PAAK und Aufheizung → Frage nach Universalität & Interpolation

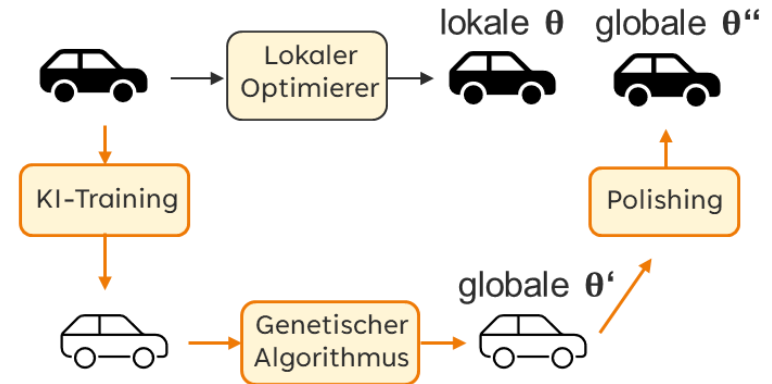
Neuer Workflow:

Optimierung mittels Genetischem Algorithmus

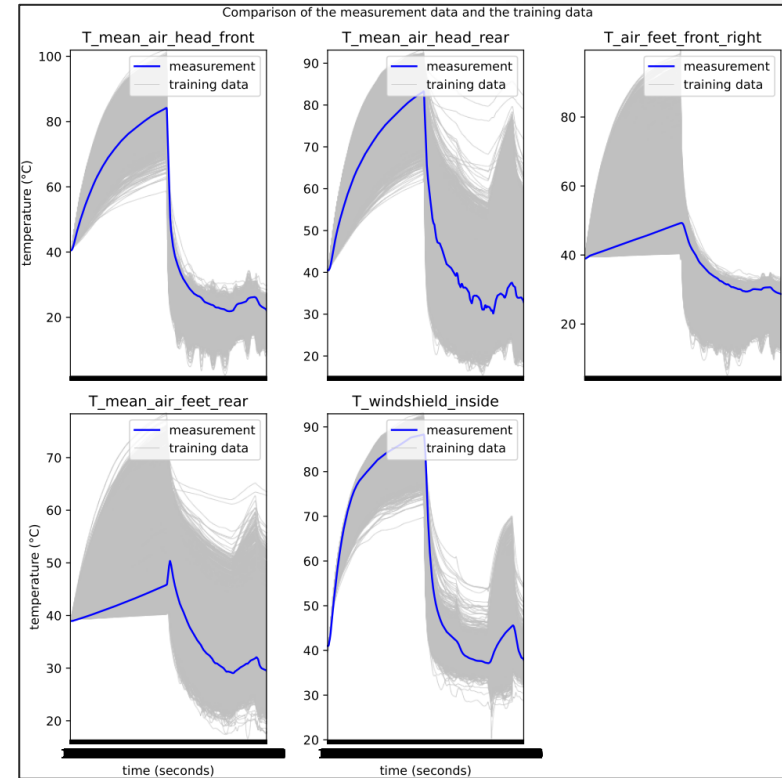
- sucht **globales Minimum**, voll **automatisiert**
- Problem: **Rechenzeit** (mehrere hunderttausend Läufe)

Idee also: nutze schnelles **KI-Ersatzmodell**

- Erzeugung Trainingsdaten automatisiert & parallelisiert
- **zeiteffiziente Optimierung** des Ersatzmodells
- Anschließendes Polishing mittels Ursprungsmodell

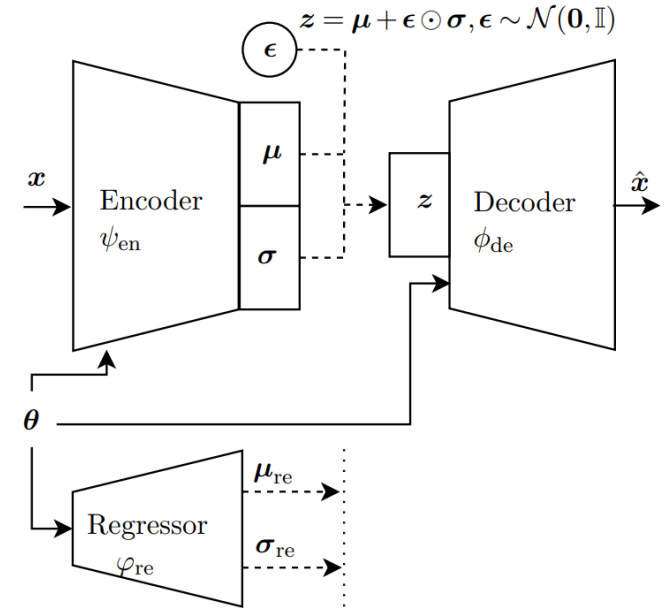


- Erster Schritt: Lerne Verhalten $x(\theta)$ des Dymola-Modells bei **festen Randbedingungen** und **veränderlichen Parametern**
- Parameterraum $\theta \in (\theta_{max}, \theta_{min})$ uniform aufspannen. Auswahl und Bereich (noch) Erfahrungswerte
- **7000 Läufe** mit vollständigem Dymola Modell, **zeitintensiv**
- Parallelisierung, verteiltes Rechnen, effiziente Kompilierung
- Prüfe, ob Zeitreihen in **Ergebnisraum** liegen
- zusätzliche **Sensitivitätsanalyse** möglich
- Trainingsdaten ($x|\theta$) liegen als Datei vor
- Teile in **3 Sets** auf: Trainings-, Validations- & Testdaten
- Anschließendes **KI-Training** auf PC mit schneller Grafikkarte oder Cloud in ca. einem Tag durchführbar



Physics-Enhanced Latent Space Variational Auto-Encoder (PELS-VAE)

- **Encoder:** Reduziere Datensatz x auf niedrig-dimensionalen latenten Raum z , der die Variation im Datensatz genügend gut repräsentiert
- Rekonstruiere Daten \hat{x} mittels eines **Decoder**-Netzwerks
- Unbeaufsichtigtes **Training des Netzwerks** beendet wenn $x = \hat{x}$
- **Validationsdaten:** Verhindere overfitting & bestimme Stopzeitpunkt
- **Testdaten:** Prüfe Güte des Netzwerks an unabhängigen Daten
- **Schwierigkeit:** Verhindere einfaches Erinnern der Daten. Lerne Wahrscheinlichkeitsverteilungen: **Variational** Auto-Encoder
- zusätzliches **Regressor-Netzwerk** lernt die Darstellung der Attribute μ und σ im latenten Raum bei gegebenen θ
- Mittels **Regressor** & **Decoder** können neue Daten **außerhalb** des Trainingssets erzeugt werden



Ergebnis des KI-Trainings




- Regressor & Decoder als **KI-Ersatzmodell**
- fähig zu **Tausenden** von Berechnungen pro Sekunde
- Ergebnisvorhersage für **feste Randbedingungen** und **beliebige Modellparameter θ**

Kalibrierung mit Genetischem Algorithmus

- Selektion von Lösungskandidaten gemäß „Fitness“
- Mutation und Rekombination
- im Beispiel ca. **400.000 Berechnungen** (abhängig von Hyperparametern), dauern nur **wenige Sekunden**

Polishing-Phase

- Ergebnisparameter dienen als Startwerte für abschließende **Kalibration des Dymola-Modells** mittels eines lokalen Optimierers



Erste Resultate vielversprechend:

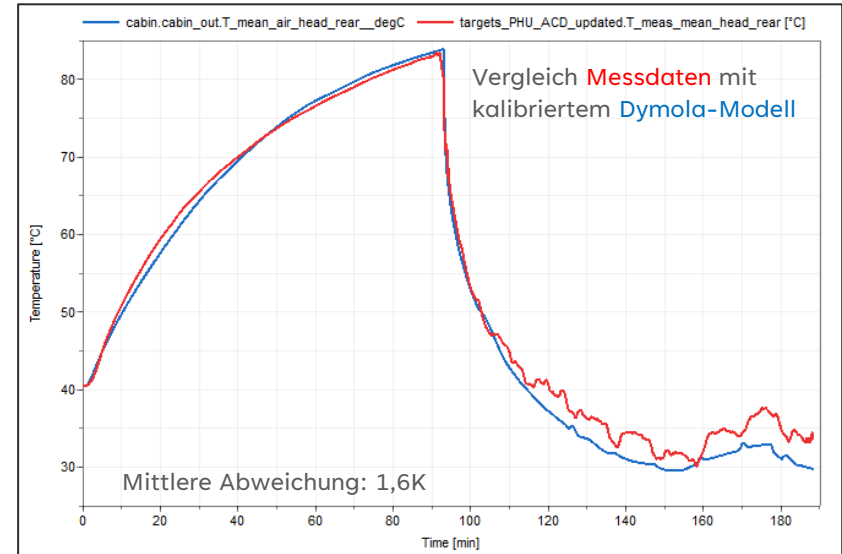

- Erhöhung **Qualität der Kalibrierung**: globales Minimum, Parametersatz für beide Szenarien
- Netto **Beschleunigung des Prozesses**
- Automatisierung/Parallelisierung → **Zeiteffizienz**
- Skriptbibliothek → Normierung & Nachvollziehbarkeit
- Verfahren perspektivisch in **JSCORE** verfügbar

weitere Methoden in Zukunft zu testen:


- **Sensitivitätsanalyse** mittels Sobol-Koeffizienten
- **BayesFlow** → Fehlerabschätzung/Varianz der Ergebnisparameter, inverse Sensitivitätsanalyse

Übertragung in andere Themenbereiche:

- Erstellung schneller Ersatzmodelle
- Komponentenkalibration & -auslegung
- Kältekreismodelle: Zielwertauslegung & Teststanddaten



- Aka, J., Brunnemann, J., Freund, S., Speerforck, A. Efficient Global Multi Parameter Calibration for Complex System Models Using Machine-Learning Surrogates. *Proceedings of the 15th International Modelica Conference (2023)*, <https://doi.org/10.3384/ecp204107>
- Zhang, Y., Mikelsons, L. Sensitivity-guided iterative parameter identification and data generation with BayesFlow and PELS-VAE for model calibration. *Adv. Model. and Simul. in Eng. Sci.* **10**, 9 (2023). <https://doi.org/10.1186/s40323-023-00246-y>



Funded by
the European Union
NextGenerationEU

Supported by:



Federal Ministry
for Economic Affairs
and Climate Action

on the basis of a decision
by the German Bundestag

Förderkennzeichen: **19I20022F**

Vielen Dank für Ihre Aufmerksamkeit!

XRG Simulation GmbH
Friedrichshofener Str. 51
85049 Ingolstadt
Germany

0841 / 99 33 05 - 60
www.xrg-simulation.de
info@xrg-simulation.de