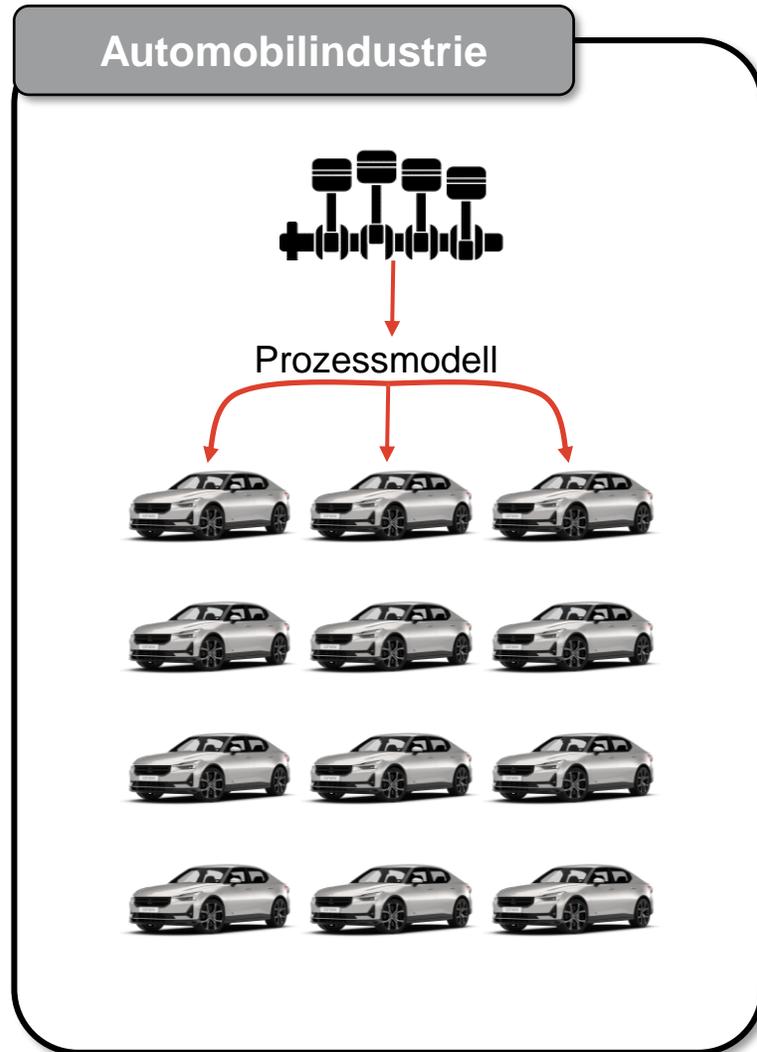
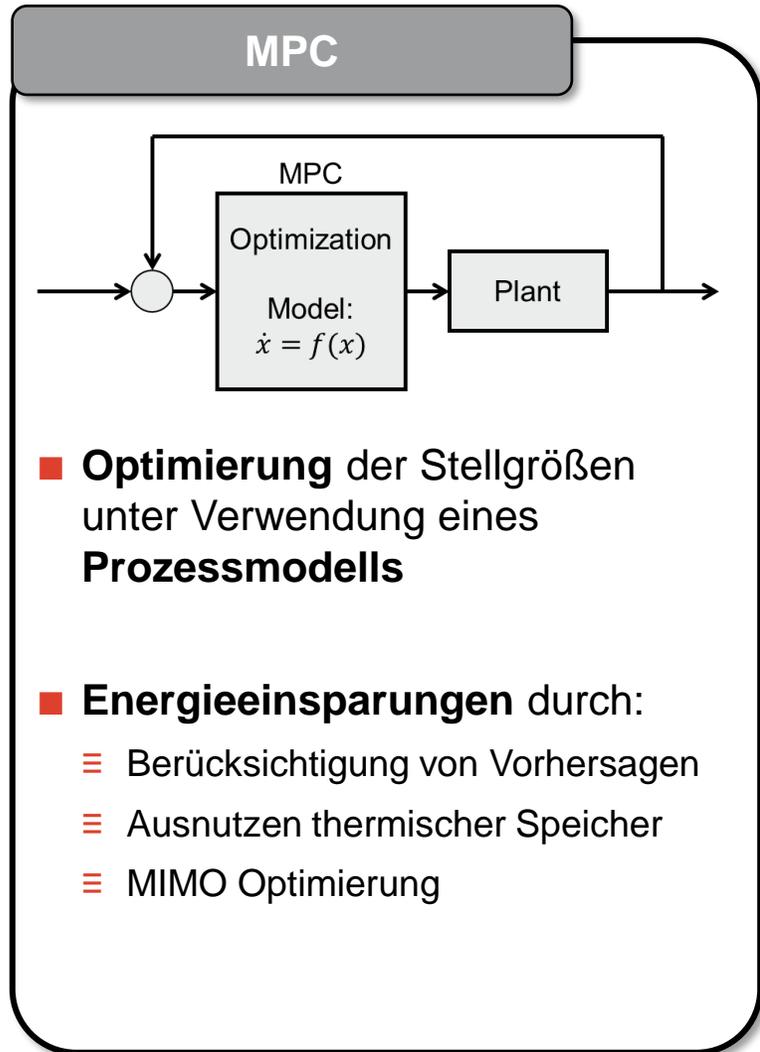


AGENT-2

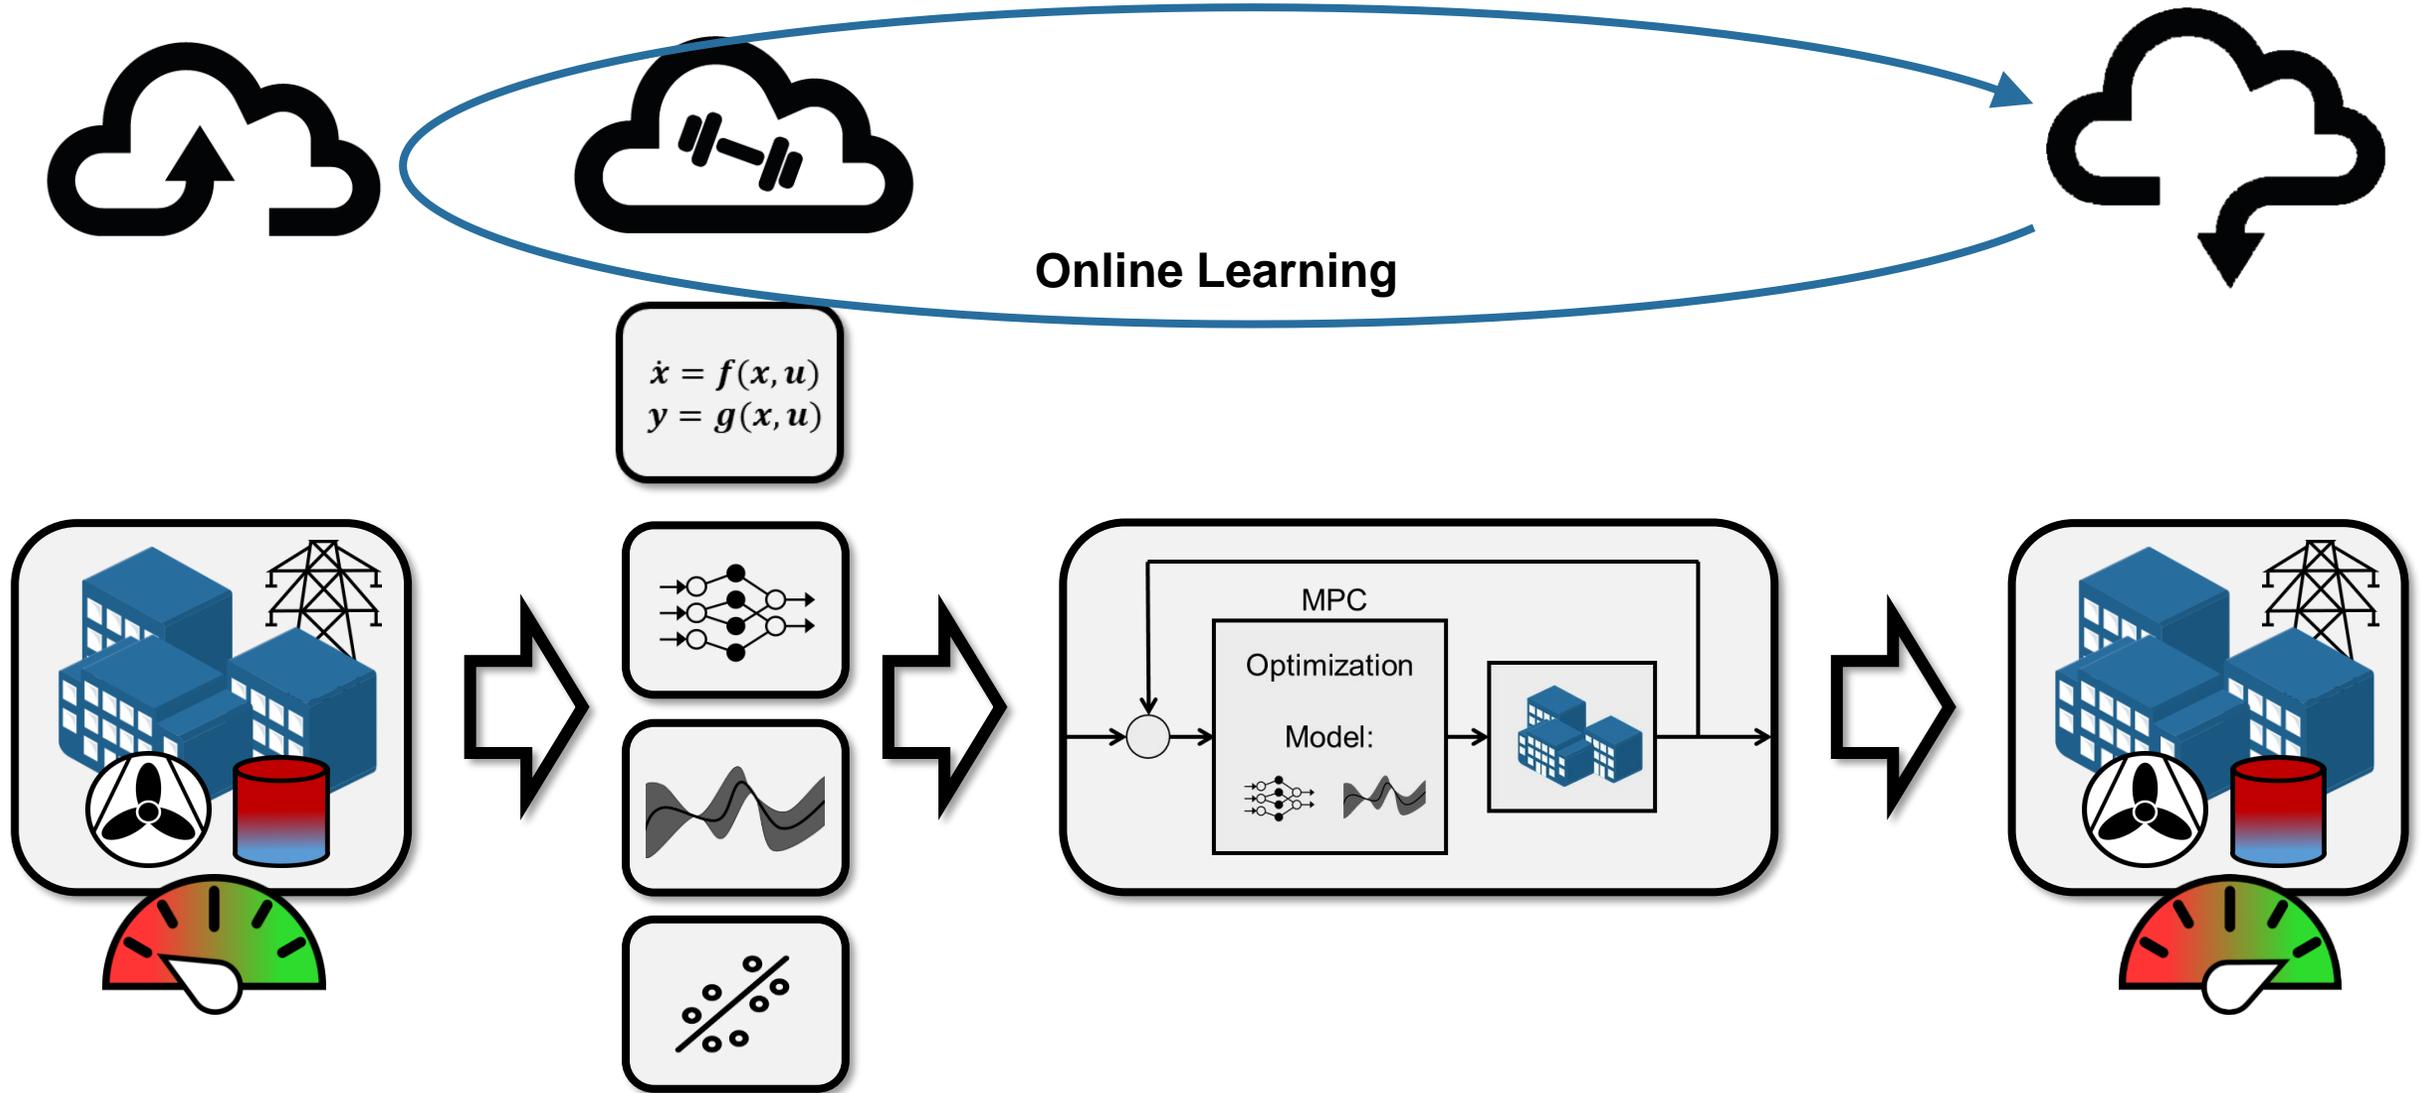
(Agentenbasierte,) Datengetriebene, selbsteinstellende Regelung von Gebäudeenergiesystemen

7. März 2024

Der hohe gebäudespezifische Modellierungsaufwand mindert bislang die praktische Anwendbarkeit von MPC

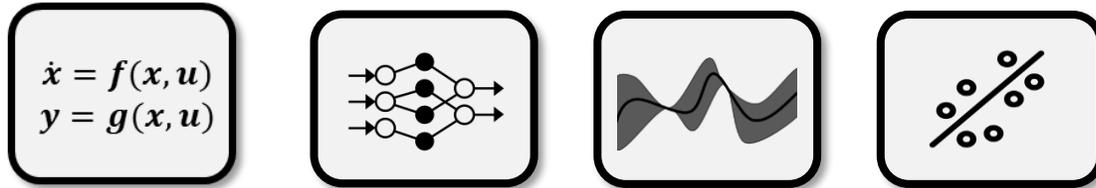


Automatisierte Implementierung von Modellprädiktiven Reglern basierend auf Monitoring Daten

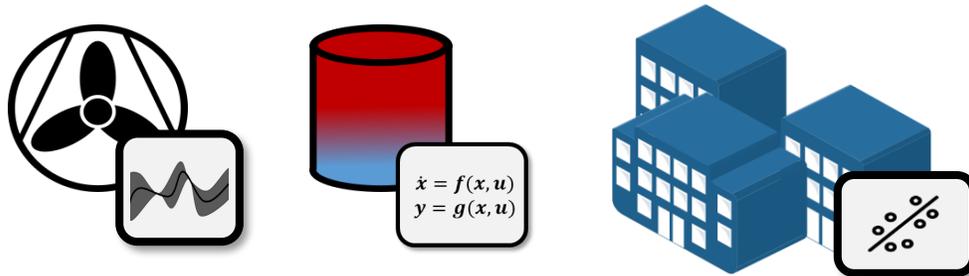


Forschungsziele RWTH im Projekt Agent II

- **Welche Modelle** des Maschinellen Lernens eignen sich besonders für die Datengetriebene MPC?

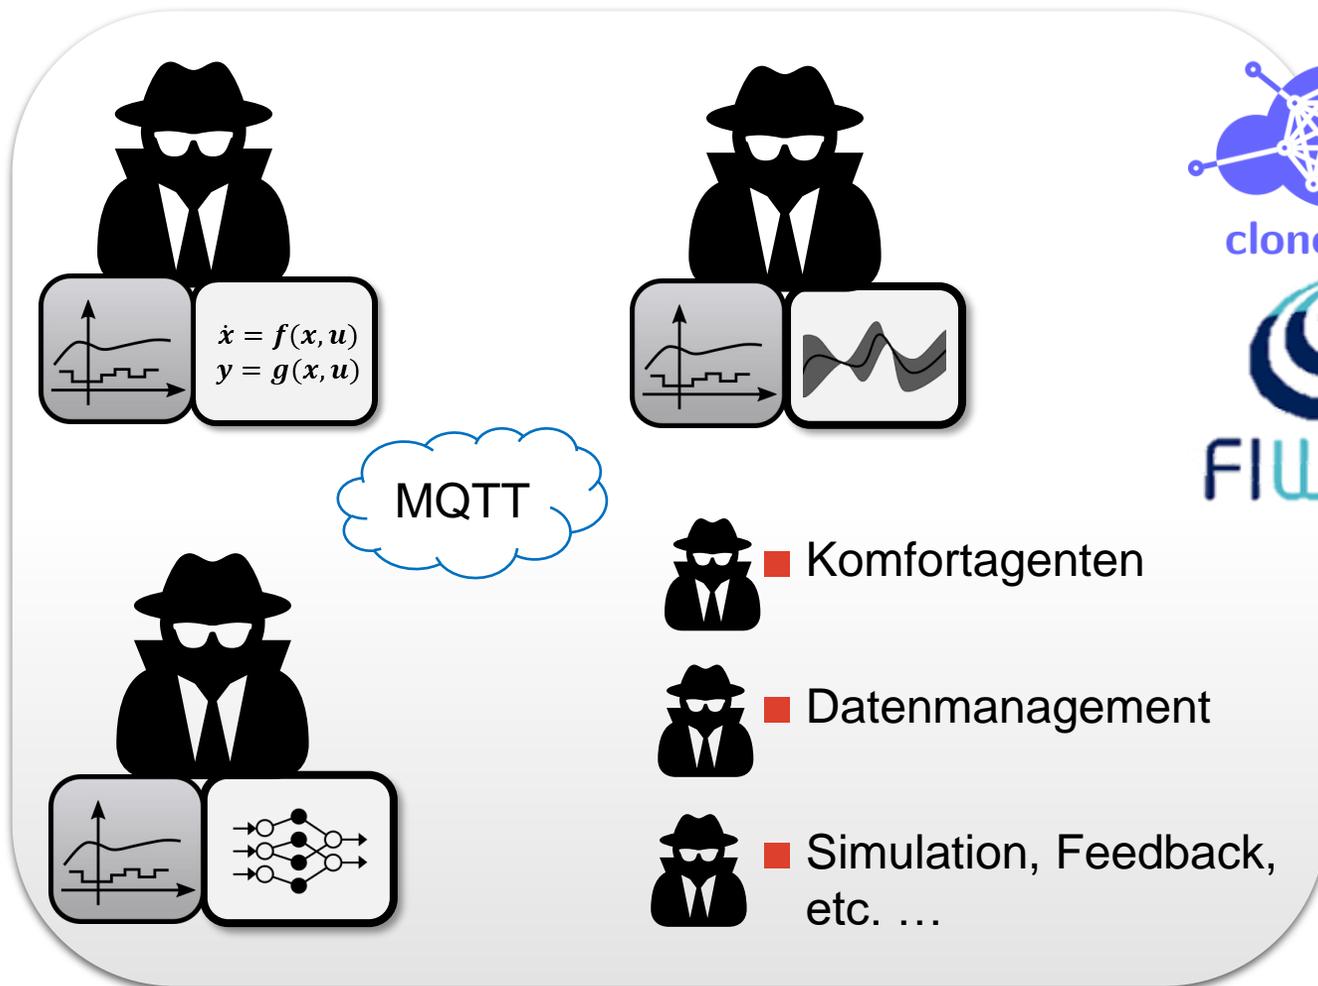


- Sollten für **verschiedene Subsysteme** verschiedene ML Typen miteinander kombiniert werden?



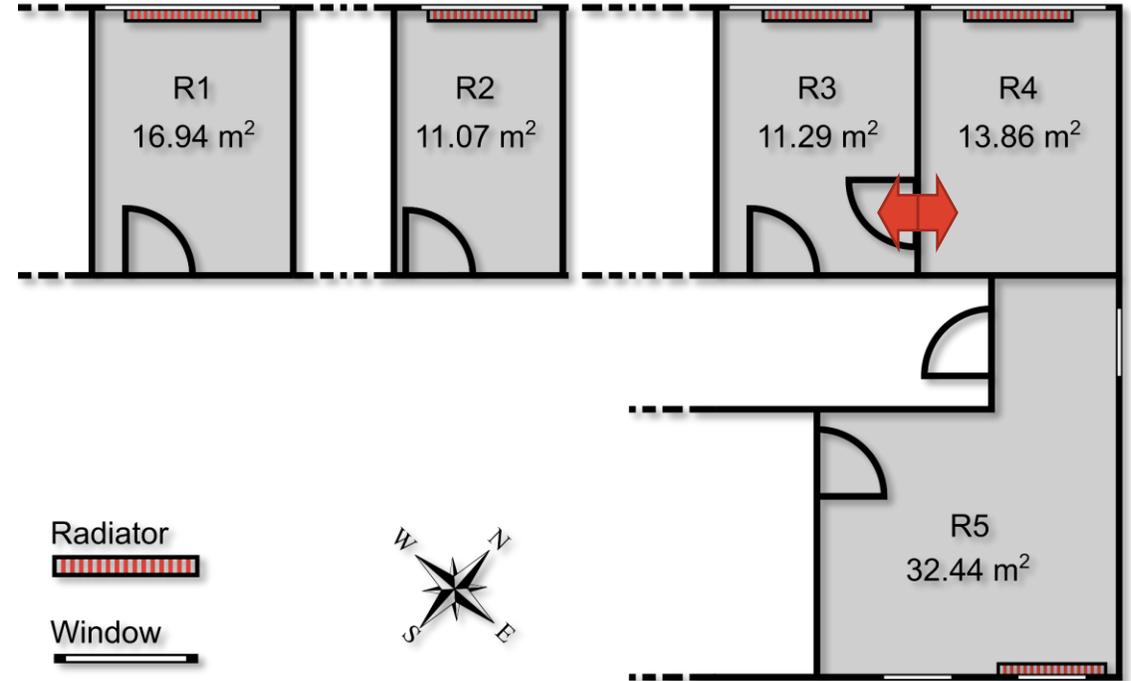
- Wie kann die **Skalierbarkeit** weiter erhöht werden?
 - ≡ Transfer / Physics-Informed Learning, Safe-Learning
 - ≡ Verteilte Datengetriebene MPC
 - ≡ Automatische Konfiguration, automatisches Parameter-Tuning

Ein weiterer Schwerpunkt des Projekts ist der Ausbau der agentenbasierten Infrastruktur aus dem Vorgängerprojekt AGENT (AgentLib: <https://github.com/RWTH-EBC/AgentLib>)

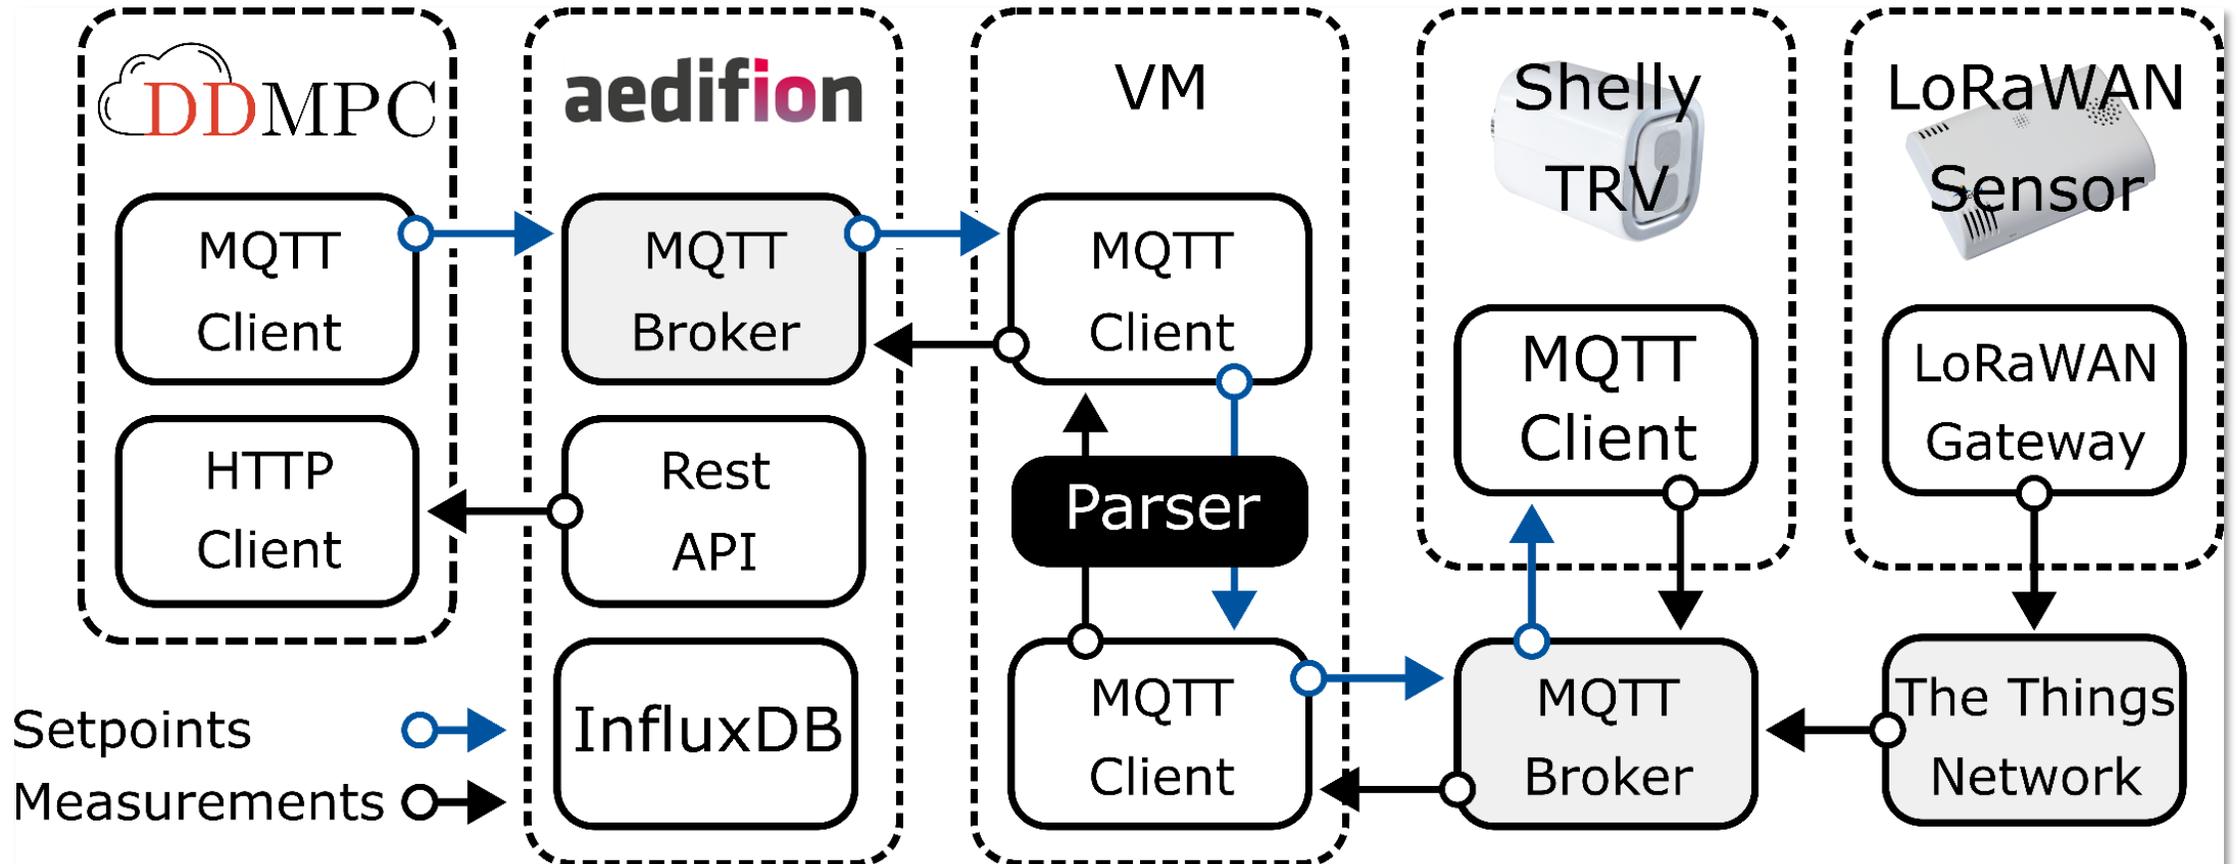


- Modulare Struktur durch Agentensysteme
- Vorgefertigte Agenten-Templates beschleunigen die Implementierung
- Agenten erfüllen spezifische Aufgaben
- Integration der Machine-Learning Modelle in die AgentLib
 - ≡ Übersetzen der Modelle in Optimierungssyntax

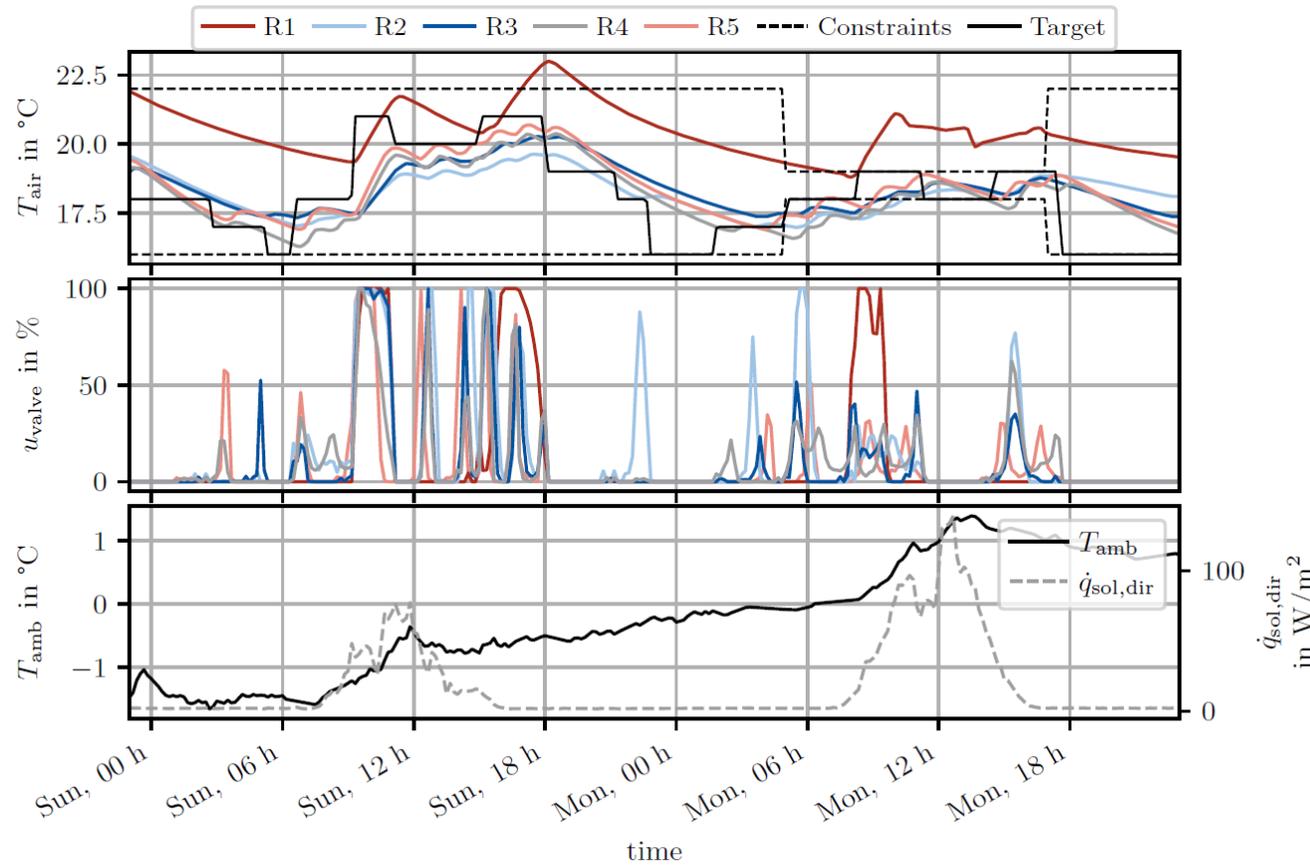
Anwendungsbeispiel: Datengetriebene Modellprädiktive Regelung eines Bürogebäudes an der RWTH Aachen



Für die Versuche wurden die Büros mit smarten Thermostatventilen und LoRaWAN Multisensoren ausgestattet und an die Cloud angebunden

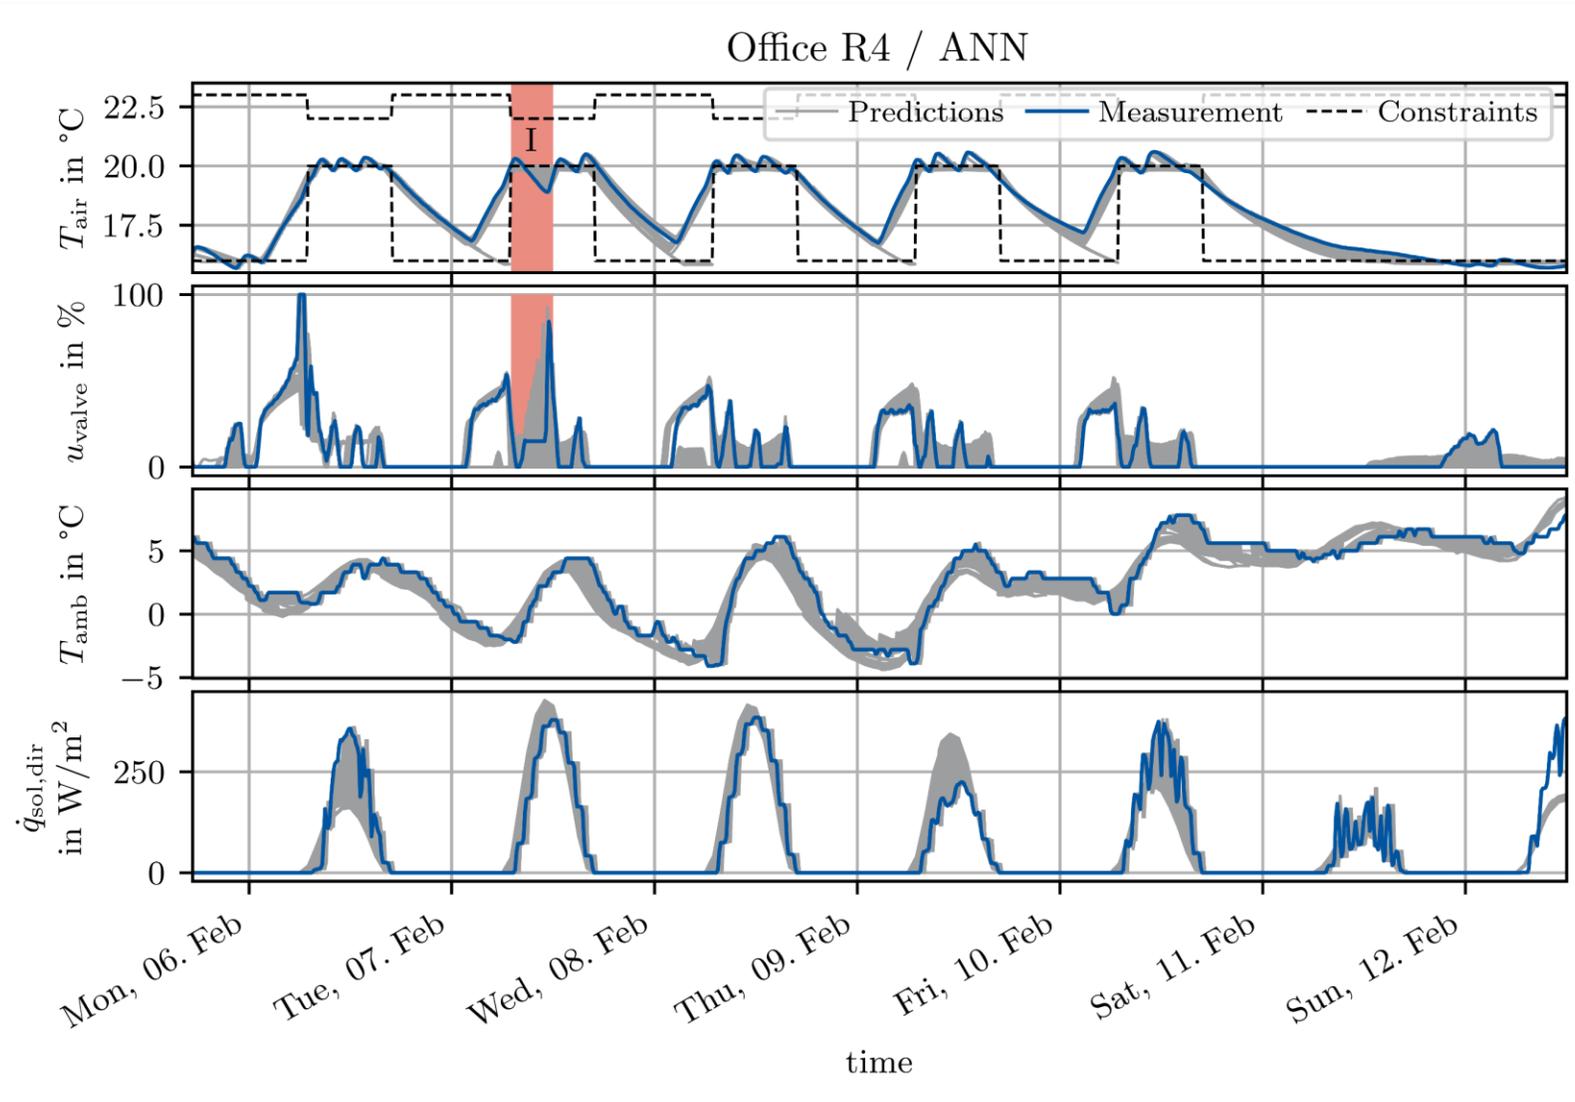


Zwei Tage initiales Training, sechs Wochen MPC Betrieb

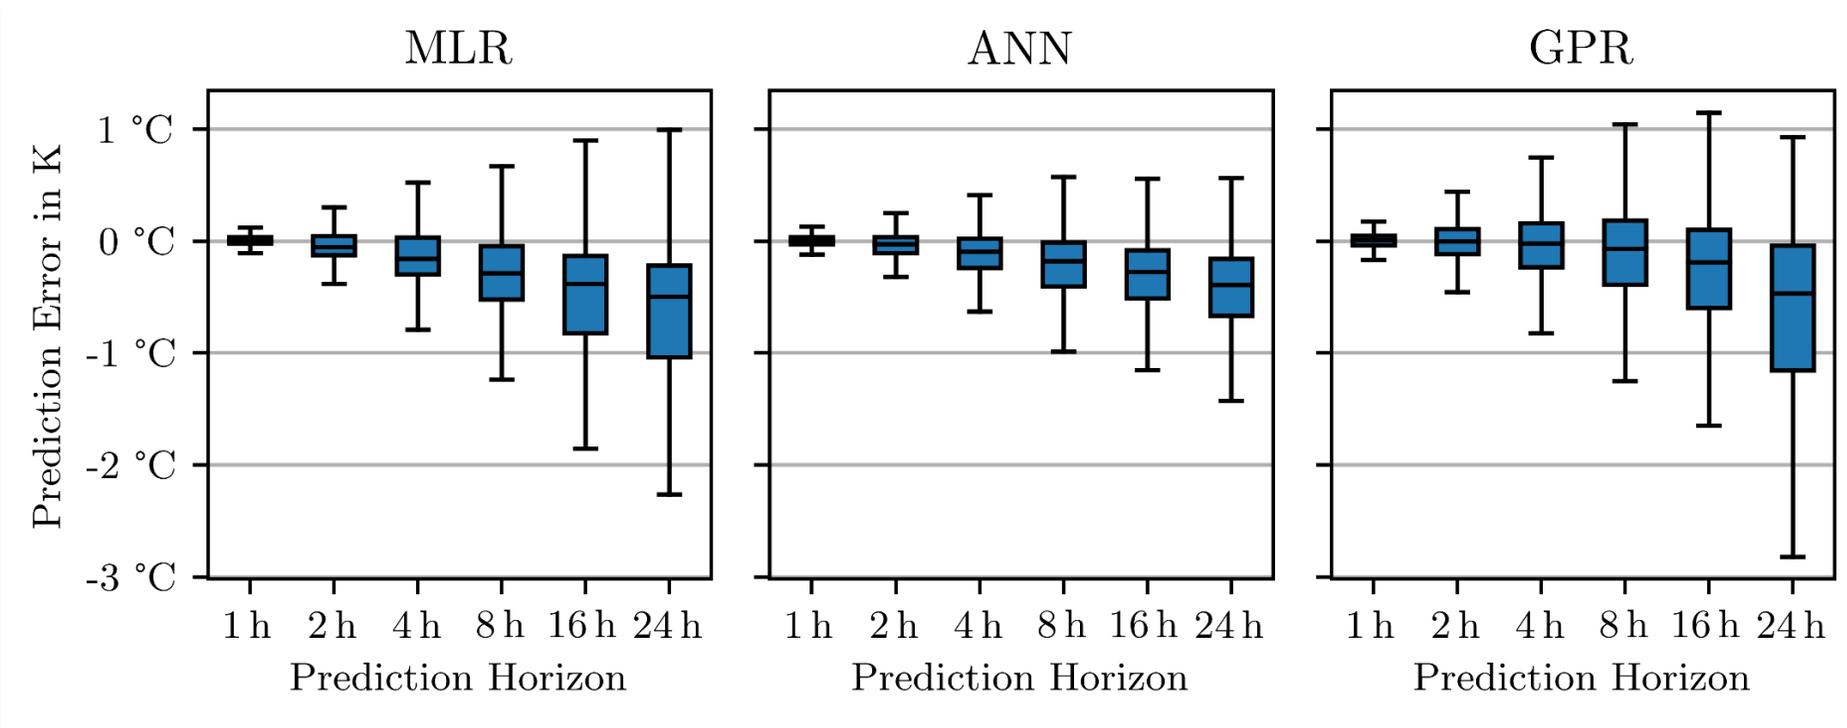


| Experiment | Period | | Office | | | |
|---------------|--------|-------|--------|-----|---------|-----|
| | from | to | R1 | R2 | R3 & R4 | R5 |
| Commissioning | 24.01 | 04.02 | ANN | GPR | PID | MLR |
| 1 | 05.02 | 12.02 | PID | MLR | ANN | GPR |
| 2 | 13.02 | 20.02 | GPR | PID | MLR | ANN |
| 3 | 21.02 | 28.02 | MLR | ANN | GPR | PID |
| 4 | 03.03 | 11.03 | ANN | GPR | PID | MLR |

Nach dem initialen Training können die Regler zuverlässig die eingestellten Temperaturgrenzen einhalten und dabei den Energieverbrauch reduzieren



ANNs können die höchste Genauigkeit erreichen



| | MLR | ANN | GPR | PID |
|--|---------|----------|--------|--------|
| Diskomfort in Kh | 10,03 | 13,54 | 15,66 | 71,89 |
| Integrale Thermostatventil- Öffnung | 325,65 | 267,55 | 275,04 | 343,80 |
| | - 5,3 % | - 22,2 % | - 20 % | |

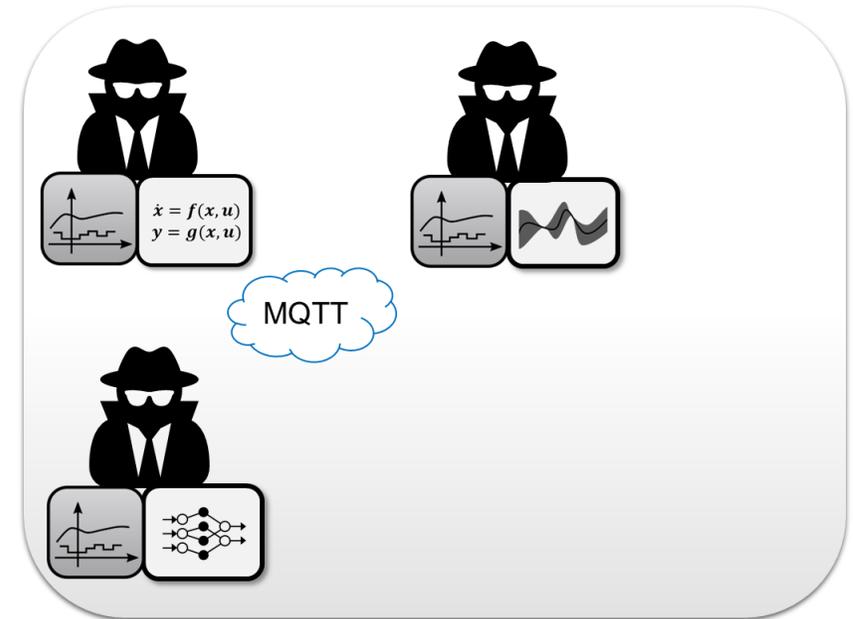
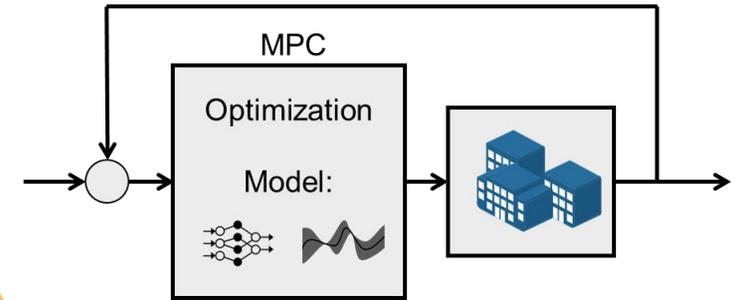
**Aber:
Einfacheres Tuning der
linearen Regler**

Ausblick: Anwendung an komplexeren Demonstratoren & Erhöhung der Skalierbarkeit



Zusammenfassung

- Machine Learning bietet die Chance die modellprädiktive Regelung skalierbarer zu machen
 - ≡ Oftmals reichen aber einfache Regressionsverfahren
- Die agentenbasierte Infrastruktur erlaubt den einfachen Umstieg von Simulation zu Experiment
- Robustere und modularere Implementierung durch Agenten



Vielen Dank für Ihre Aufmerksamkeit!

Phillip Stoffel, M.Sc.
Teamleiter Gebäudeautomation

phillip.stoffel@eonerc.rwth-aachen.de

RWTH Aachen University
E.ON Energy Research Center
Institute for Energy Efficient Buildings and Indoor Climate

Mathieustraße 10
52074 Aachen
www.eonerc.rwth-aachen.de/ebc

Supported by:



on the basis of a decision
by the German Bundestag

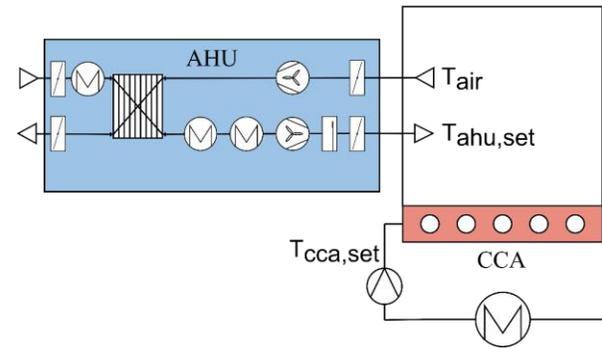
We gratefully acknowledge the financial support by the Federal Ministry for Economic Affairs and Climate Action (BMWK), promotional reference 03EN1066.



Anwendungsbeispiel 2: Versuchshalle am ERC



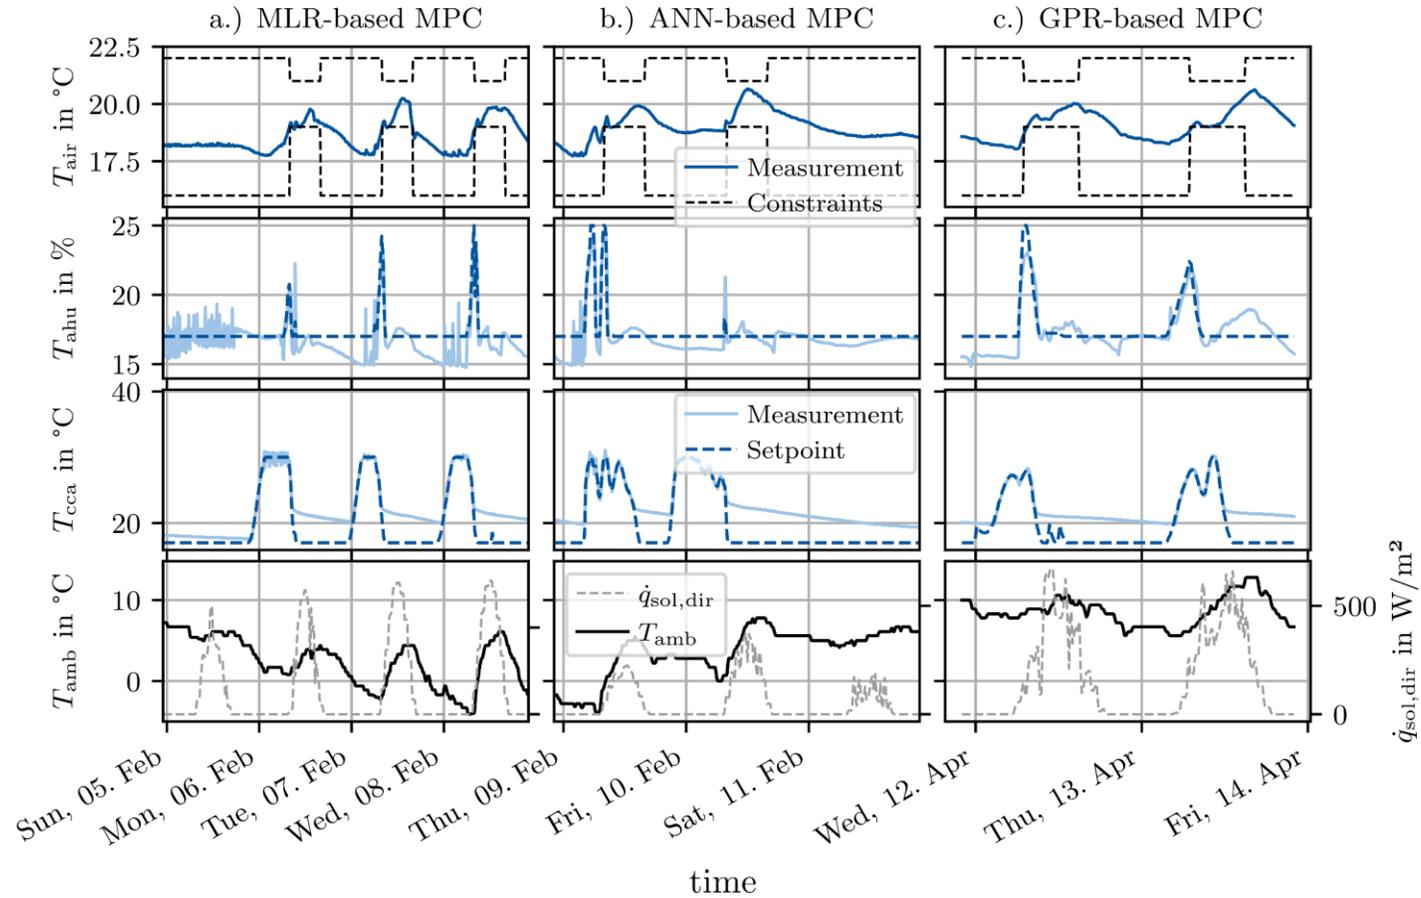
a.) Schematic Energy System



b.) Test Hall of the E.ON Energy Research Center
in Aachen, Germany



Auch hier können die Temperaturgrenzen zuverlässig eingehalten werden und der Energieverbrauch minimiert werden



Einfacheres Tuning der linearen Regler

Die AgentLib bietet einen Rahmen zur Ausführung von Services, Reglern und Simulationen – Als Simulation, in Echtzeit, lokal oder verteilt

■ Ausführung von **Services, Reglern und Simulationen** – **Als Simulation, in Echtzeit, lokal oder verteilt**

≡ Beschleunigt Übergang von Simulation zu Experiment

■ Vorgefertigte Module und Plugins: **AgentLib Core**

= Ausführung von FMUs

= Kommunikation lokal, über MQTT und mit Fiware

≡ **Digital Twin Services**

= Fehlererkennung

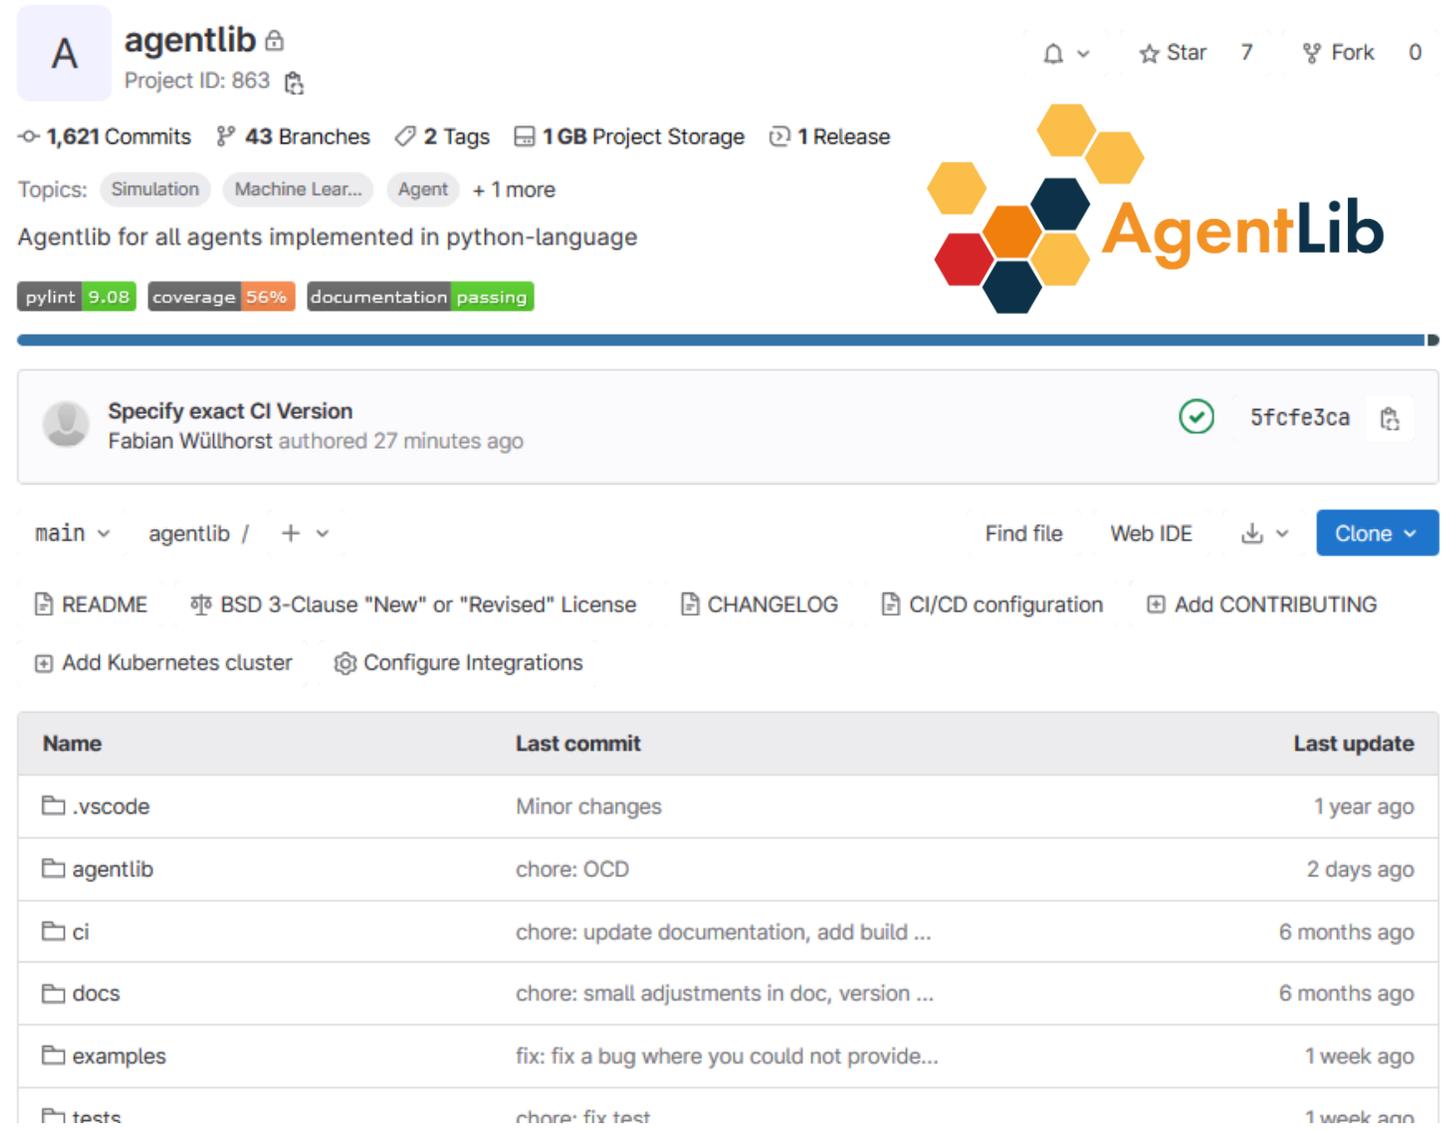
≡ **AgentLib_MPC**

= MPC

= Datengetriebene Modellierung

= Verteilte Optimierung (ADMM)

■ Publikation in Vorbereitung



agentlib  Project ID: 863 

1,621 Commits 43 Branches 2 Tags 1GB Project Storage 1 Release

Topics: Simulation Machine Lear... Agent + 1 more

Agentlib for all agents implemented in python-language

pylint 9.08 coverage 56% documentation passing

Specify exact CI Version  5fcfe3ca 
Fabian Wüllhorst authored 27 minutes ago

main agentlib / + Find file Web IDE Clone

README BSD 3-Clause "New" or "Revised" License CHANGELOG CI/CD configuration Add CONTRIBUTING

Add Kubernetes cluster Configure Integrations

| Name | Last commit | Last update |
|--|---|--------------|
|  .vscode | Minor changes | 1 year ago |
|  agentlib | chore: OCD | 2 days ago |
|  ci | chore: update documentation, add build ... | 6 months ago |
|  docs | chore: small adjustments in doc, version ... | 6 months ago |
|  examples | fix: fix a bug where you could not provide... | 1 week ago |
|  tests | chore: fix test | 1 week ago |

Ausblick: Verteilte Optimierung mit der AgentLib

