

KI in der Gebäudeautomation jenseits des Hypes

Zwei belastbare Use Cases für Diagnose,
Datenanalyse und lernende Regelung

**Predictive Maintenance von
Ventilen und Pumpen**

**Reinforcement Learning
für Wärmepumpen**

Prof. Dr.-Ing. Seyed H. Sagheby
Gebäudeenergie- und
Informationstechnik

Keynote · tab Fachforum Zukunft der Gebäudeautomation

Zielbild

Keine KI-Demo.
Sondern konkrete
Anwendungsfälle, die zeigen, wo
Datenanalyse in der GA heute
realen Mehrwert liefert – und wo
die methodischen Grenzen liegen.

1

Asset Health

Anomalien erkennen, Ausfälle
früher sichtbar machen,
Wartung priorisieren.

2

Control Intelligence

Betrieb in Echtzeit optimieren –
unter Kosten-, Komfort- und
Verschleißzielen.

Warum ist dieses Thema jetzt relevant

Vier Treiber für belastbare KI-Anwendungen in der GA

- Mehr Betriebsdaten aus GLT/BMS, Feldgeräten und Cloud-Plattformen
- Steigender Druck auf Energieeffizienz, Transparenz und Nachweisbarkeit
- Komplexere Betriebsziele: Komfort, Kosten, CO₂, Verfügbarkeit, Lebensdauer
- Fachkräftemangel: Ingenieurleistung muss dort eingesetzt werden, wo sie den größten Hebel hat

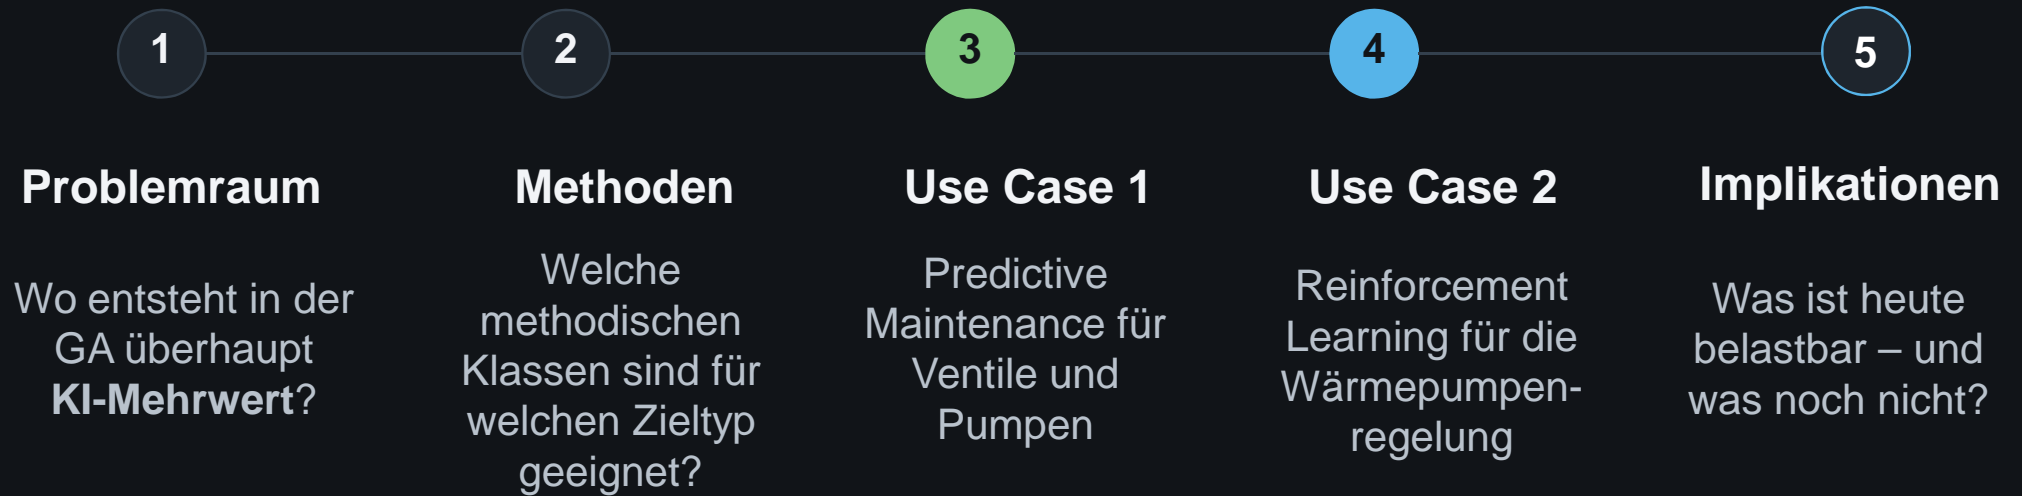
Von Daten zu Betriebswirkung



Entscheidend ist nicht "mehr KI", sondern die Kopplung von Datenqualität, Fachlogik und messbarem Nutzen.

Ablauf im Vortrag

vom Problemraum über die Methoden bis zu zwei belastbaren Use Cases



Use Case 1 – Predictive Maintenance von Ventilen und Pumpen

Die Fallstudie zeigt, wie sich vorhandene Trenddaten in ein **fault-label-freies Zustandsmodell** überführen lassen.

Warum der Use Case praktisch relevant ist

- Zeitbasierte Wartung ist oft zu früh, reaktive Wartung zu spät.
- BACnet- und Modbus-fähige Komponenten liefern bereits Signale, die als „PdM-Proxys“ nutzbar sind.
- Im Fokus der Arbeit: Umwälzpumpe und Regelventil in einem Heizkreis, weil beide wichtige Störquellen im Betrieb sein können.

Überwachte Größen

Pumpe

- Leistung
- Volumenstrom

Praxisnahe **Features** aus Modbus-Listen von WILO und Belimo, u. a. Drehzahl, Druckdifferenz, Motortemp., Aktordrehmoment, Einlassdruck des Ventils, usw.

Ventil

- Stellung
- Druckabfall

Methoden für Predictive Maintenance – nicht jede Aufgabe braucht „KI“!

Regelbasiert / Schwellenwerte

- schnell umsetzbar
- hohe Erklärbarkeit
- gut bei klaren Grenzwerten
- anfällig für Fehlalarme und Kontextwechsel

Anomalieerkennung

- lernt „normalen“ Betrieb multivariat
- geeignet bei wenigen Fehlerlabels
- nützlich für Vorwarnung: *unterstützende „KI“ für den Betriebsingenieur*
- erfordert saubere Betriebssegmentierung

Supervised Klassifikation / Prognose

- beste Wahl bei bekannten Fehlerbildern mit fault-label
- ermöglicht Priorisierung und Restlebensdauer-Nähe
- braucht kontextbewusste gelabelte Fälle
- im Feld oft durch Datenverfügbarkeit limitiert

Praxisbeobachtung: In GA-Projekten sind Datenqualität und Anschluss an den Wartungsprozess oft limitierender als die Modellklasse.

Use Case 1 – Predictive Maintenance von Ventilen und Pumpen

Die Fallstudie zeigt, wie sich vorhandene Trenddaten in ein fault-label-freies Zustandsmodell überführen lassen.

Vorgehen

1 Datenbasis

6 Monate Heizperiode, 15-Minuten-Intervall, physikalisch plausibles Raummodell, nur Normalbetrieb als Baseline

2 Modellvergleich

Ridge Regression vs. Gradient Boosting vs. MLP; Training auf 80 % der Zeitreihe; σ aus Trainingsresiduen (Differenz zw. Vorhersage und „tatsächlicher“ Wert)

3 Anomalieerkennung

Im „Betrieb“: Residuum $e(t) = \text{Messwert} - \text{Vorhersage}$;
Anomalie bei $|e(t)| > 2,5\sigma$

4 Zustandslogik

Wöchentliche Aggregation der Anomalierate;
Ratio $\leq 1,5 \rightarrow \text{Normal}$, $\leq 3 \rightarrow \text{Warnung}$, $> 3 \rightarrow \text{Kritisch}$

Hauptvorteil

Das Verfahren braucht keine Fehlerdaten für das Training. Es lernt zunächst „normalen“ Betrieb und bewertet dann persistente Abweichungen als Zustandsindikator.

Ergebnisse des PdM-Ansatzes


Die Arbeit liefert eine robuste Referenzarchitektur: Regression → Residuen → z-Score → Zustandsklassifizierung

Modellvergleich

Vergleich der Performance mittels Evaluationsmetriken

	Ridge Regression (linear)		Gradient Boosting (baumbasiert)		Multi-Layer Perceptron (Neurales Netz)	
Pumpe - Leistungsaufnahme	R ²	0,9639	R ²	0,9575	R ²	0,9507
	RMSE	0,1962	RMSE	0,2130	RMSE	0,2287
	MAE	0,1557	MAE	0,1664	MAE	0,1786
Pumpe - Volumenstrom	R ²	0,9564	R ²	0,9482	R ²	0,3053
	RMSE	0,0035	RMSE	0,0038	RMSE	0,0138
	MAE	0,0028	MAE	0,0031	MAE	0,0096
Ventil - Ventilstellung	R ²	0,9044	R ²	0,8713	R ²	0,8417
	RMSE	0,5014	RMSE	0,5774	RMSE	0,6429
	MAE	0,4023	MAE	0,4561	MAE	0,4907
Ventil - Druckabfall	R ²	0,7627	R ²	0,5099	R ²	0,0034
	RMSE	0,0004	RMSE	0,0006	RMSE	0,0070
	MAE	0,0003	MAE	0,0005	MAE	0,0054

Beste Performance



© A. Wibawa

Ridge generalisiert hier am besten, weil die physikalischen Zusammenhänge im Heizkreis überwiegend linear sind.

Wesentliche Kennzahlen

R² auf Testdaten

Pumpe Leistung 0,9639

Pumpe Volumenstrom 0,9564

Ventil Stellung 0,9044

Ventil Druckabfall 0,7627

Anomalieschwelle

$|e(t)| > 2,5\sigma$ aus Trainingsresiduen

Die Kernidee: Nicht der einzelne Anomalie-Datenpunkt ist entscheidend, sondern wie häufig Anomalien in einem rollierenden Zeitfenster auftreten. Eine hohe Anomalie-Rate über einen Zeitraum deutet auf systematische Degradation hin, nicht auf zufälliges Rauschen.

Ergebnisse des PdM-Ansatzes

Die Arbeit liefert eine robuste Referenzarchitektur: Regression → Residuen → z-Score → Zustandsklassifizierung

Baseline-Bestimmung

Mittelwert von der Anzahl der Anomalie aller Wochen

Wöchentliche Aggregation

Zählung der Anomalien in einem rollierenden Fenster von 672 Zeitstempeln (1 Woche)

Zustandslogik (Anomaliestärke)

Bestimmung des Schweregrads des Fensters

- Ratio = Anzahl Anomalien / Baseline
- Ratio $\leq 1,5$ Normal
- Ratio ≤ 3 Warnung
- Ratio $> 3,0$ Kritisch

Das Grundkonzept (Regression → Residuen → z-Score → Zustandsklassifizierung) ist auf jede Anlage übertragbar.

Ohne Fehlersamples umsetzbar.

Für reale Anlagen bleiben Kalibrierung und Nachtraining mit echten Trenddaten entscheidend.

Praxisbotschaft

Die Methode ist Transferierbar als Referenzarchitektur für überwachte TGA-Komponenten

Use Case 2 – Wärmepumpenregelung: warum klassische Strategien an Grenzen stoßen können

Problemraum

- Volatile Strompreise und Lastverschiebungspotenziale verändern die ökonomisch optimale Betriebsweise
- Gebäude und Heizkreise besitzen thermische Trägheit – **Hypothese:** optimale Entscheidungen sind sequenzabhängig und vorausschauend
- Die Ziele konkurrieren: Energiekosten, thermischer Komfort und Anlagenlebensdauer
- Konventionelle rule-based / PI-Strategien reagieren robust, aber meist nicht multikriteriell und nicht vorausschauend

Wie RL hier überhaupt sinnvoll wird

Zustand	Temperaturen, Setpoints, Belegung, Wetter- und Preisprognosen
Aktion	stündliche Vorgabe des Verdichter-Modulationssignals (0–1)
Reward	Kosten + Komfort + Cycling / Lebensdauer in einer Zielfunktion
Lernen	Optimale Policy aus mehrere Episoden der Interaktionen, statt aus fest codierten Regeln

Methodenlandschaft für die Regelung

Die methodische Frage ist nicht „RL oder nicht“, sondern welches Verfahren zum Ziel- und Randbedingungsprofil passt

Ansatz	Modellbedarf	Prognosen integrierbar	Mehrziel-Optimierung	Erklärbarkeit / Reife
Rule-based	gering	begrenzt	gering	sehr hoch
PI / PID	gering	nein	gering	sehr hoch
MPC	hoch	ja	hoch	hoch
Reinforcement Learning	explizit nicht zwingend	ja	hoch	mittel / ausbaufähig

In der Fallstudie wurde RL gewählt, weil Kosten, Komfort und Cycling über einen längeren Zeithorizont gekoppelt optimiert werden sollen.

Fallstudie: RL-gestützte Wärmepumpenregelung

Die Arbeit untersucht RL zur multi-objektiven Optimierung von Kosten, Komfort und Anlagenlebensdauer

Experiment-Setup

- BOPTEST-Simulationsframework, validiertes Wohngebäudemodell (192 m², Brüssel)
- 210-tägige Heizperiode; stündliche Regelung; Benchmark gegen RBC / PI-Basisregelung
- Aktionsraum: Verdichter-Modulationssignal 0–1
- Algorithmen: PPO, SAC, TD3

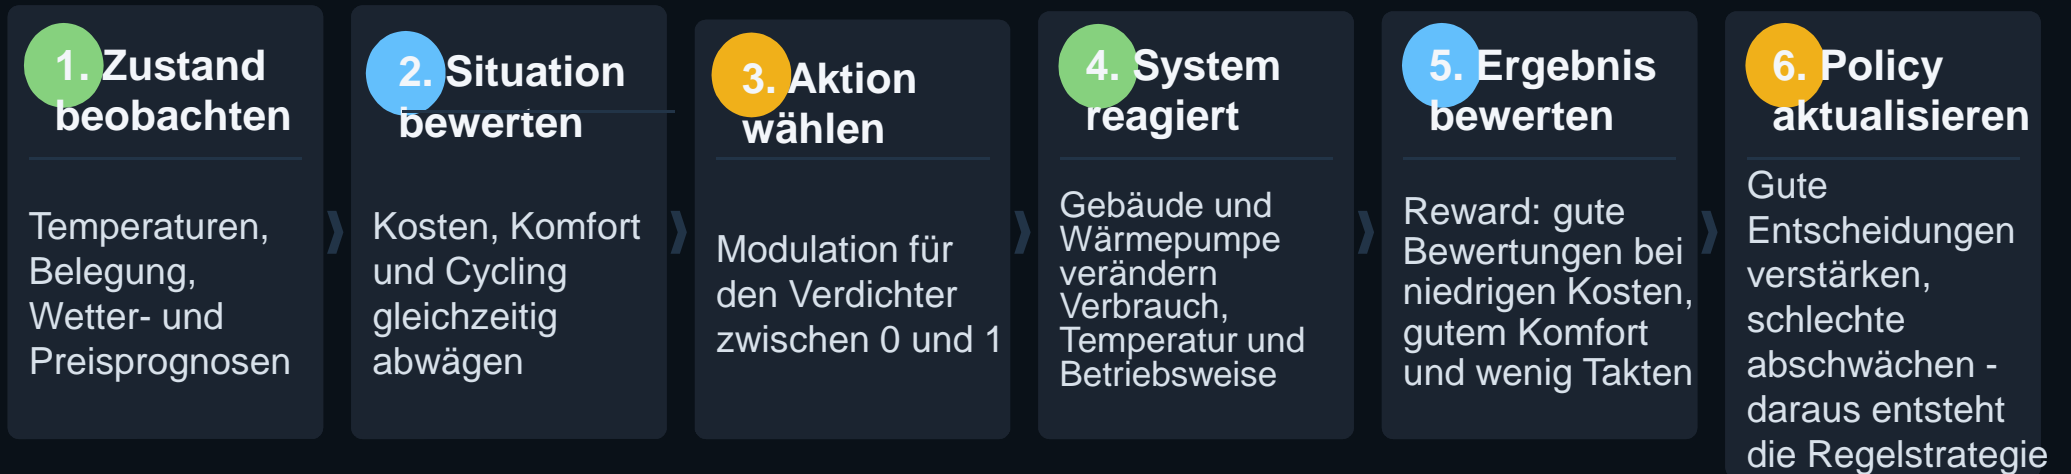
KPI-Rahmen: Energiekosten ·
thermischer Diskomfort · Zyklen / Woche
· SCOP · aktive Laufzeit

Schrittweiser Trainingsansatz

- 1 Basic control** Grundlegende Temperaturführung
- 2 Forecast integration** Wetter- / Preisvorausschau
- 3 Occupancy-aware comfort** Belegungsabhängige Komfortgrenzen
- 4 Cost optimization** Kostenminimierung im Heizbetrieb
- 5 Cycling penalty** Anlagenschonung / Verdichterzyklen

Wie Reinforcement Learning eine Wärmepumpe regelt

Schritt-für-Schritt: von der Beobachtung des Anlagenzustands zur trainierten Policy



Training: viele Wiederholungen in der Simulationsumgebung

Warum Prognosen wichtig sind:

Der Agent kann vorheizen, Last verschieben und auf günstige Strompreisenster reagieren, statt nur auf den aktuellen Zustand zu antworten.

Betrieb: trainierte Policy liefert Stellgröße

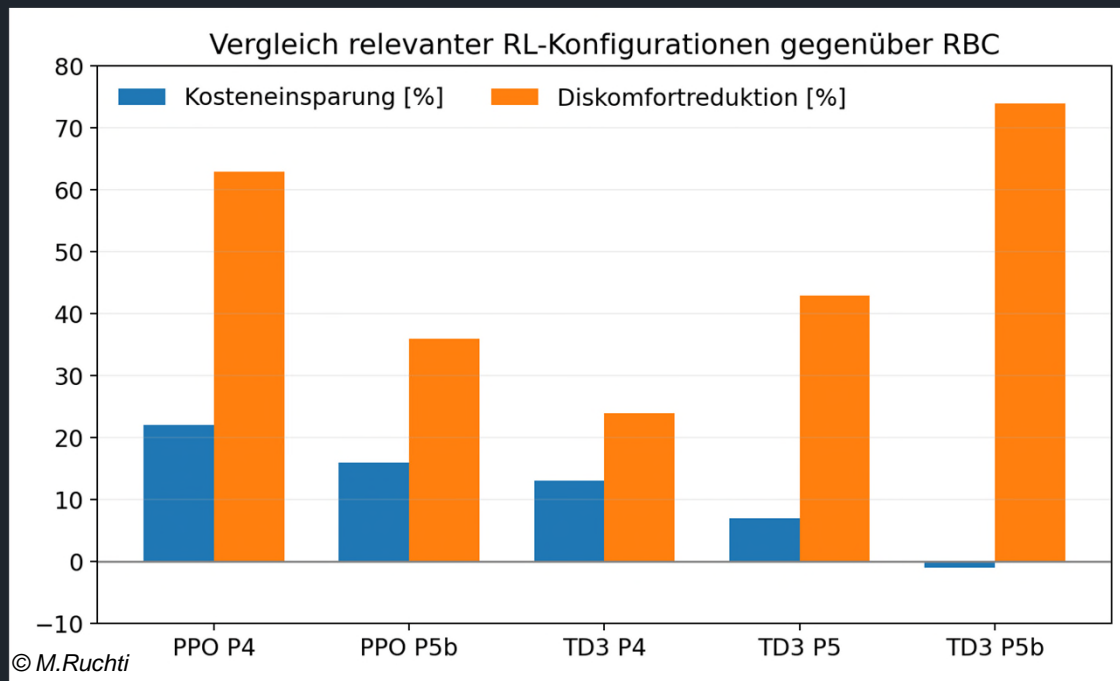
Im späteren Einsatz:

Es wird nicht frei im Feld exploriert; die zuvor offline trainierte Policy wird als ‚Regelstrategie‘ verwendet.

Merksatz: RL lernt hier keine Physikformeln, sondern eine Entscheidungsstrategie für den Betrieb der Wärmepumpe.

Zentrale Ergebnisse im Überblick

Vergleich relevanter Konfigurationen gegenüber RBC

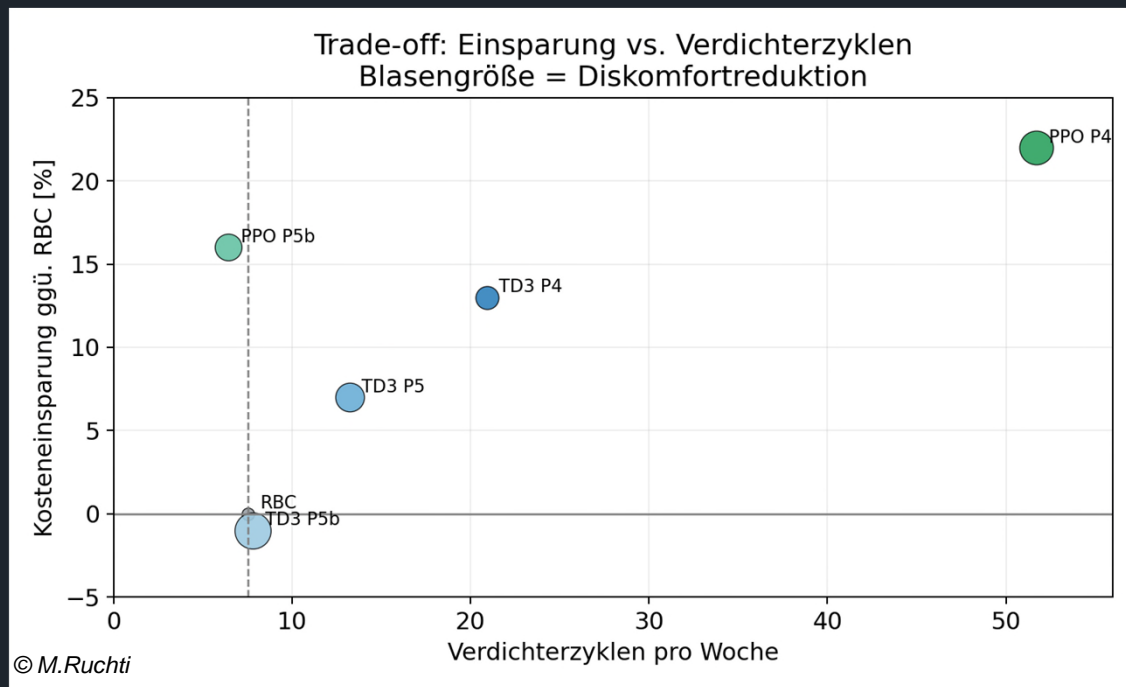


*Wesentliche Einsparquelle: Hilfsaggregate (Ventilator / Pumpe)
-45,6 %, nicht primär eine bessere Verdichtereffizienz.*

Interpretation

- PPO Phase 4 liefert den stärksten Kosteneffekt (-22 %), aber mit sehr hoher Schalthäufigkeit
- PPO Phase 5b ist der belastbarste Kompromiss: -16 % Kosten, -36 % Diskomfort, 6,4 Zyklen/Woche
- TD3 erreicht in Phase 4 noch -13 %, verliert bei starker Cycling-Beschränkung jedoch den Kostenvorteil
- SAC erreichte in dieser Arbeit in keiner Konfiguration Kostengleichheit zum RBC

Entscheidend ist der Trade-off – nicht nur der Bestwert



Was daraus methodisch folgt

- Unbeschränktes RL kann „zu gut“ auf den Zielwert Kosten optimieren und dafür Schaltbelastung in Kauf nehmen
- Eine explizite Cycling-Penalty verändert nicht nur das Ergebnis, sondern die gesamte Betriebsstrategie
- Für den Praxiseinsatz ist daher die Reward-Definition ebenso wichtig wie die Algorithmuswahl
- Empfehlung der Studie: PPO Phase 5b als praktikable Startkonfiguration

Was ist davon aus Sicht der Praxis übertragbar?

1. Daten & Modellbasis

- saubere Zeitreihen und Betriebszustände
- valider Simulations- / Digital-Twin-Rahmen
- klare KPI-Definition vor dem Training

2. Guardrails & Governance

- Fallback-Regelung soll erhalten bleiben
- harte Sicherheitsgrenzen außerhalb des Lernens
- Paralleles Monitoring von Drift, Komfort und Cycling

3. Einführung als Pilot

- zuerst auf flexiblen, gut instrumentierten Anlagen
- mit M&V und Vergleichsbaseline
- nicht als Black Box, sondern als kontrollierte Betriebsfunktion

Kernaussage: RL sollte in der Gebäudeautomation nicht als autonome Black Box eingeführt werden, sondern als kontrollierte Optimierungsschicht mit klaren Grenzen.

Synthese der beiden Use Cases

Beide Beispiele zeigen unterschiedliche Ebenen von KI-Wirkung

Zeithorizont

Analyse → Diagnose → Prognose → Entscheidung

**Use Case 1
Predictive
Maintenance**

**Use Case 2
RL-Regelung**

kurzfristig

langfristig

Gemeinsame Voraussetzungen

- robuste Datenpipeline und saubere Zustandslogik
- enge Kopplung zwischen Domänenwissen und Modellierung
- klare KPIs und Erfolgsdefinition
- Transparenz darüber, was das System darf – und was nicht

Fünf Thesen für die konkrete KI-Anwendung in der Gebäudeautomation

- 1 Der **wirtschaftliche Hebel** entsteht dort, wo Daten direkt in Betriebsentscheidungen oder Wartungsprioritäten übersetzt werden.
- 2 Nicht jeder datenreiche Use Case braucht sofort komplexe KI – aber jeder sinnvolle Use Case braucht saubere Kontextlogik mit Domänenwissen
- 3 Bei lernender Regelung ist die Zielfunktion ein Engineering-Artefakt: Reward Design entscheidet über Praxistauglichkeit.
- 4 Die Einführung der vorrausschauende Intelligenz in der Regelung gelingt über nachgewiesene Piloten, Guardrails und Vergleichsbetrieb – nicht über Black-Box-Versprechen.
- 5 Für die GA ist KI dann relevant, wenn sie Fachwissen skaliert; nicht wenn sie es ersetzt.

Vielen Dank.

Fragen oder Erfahrungsberichte aus der Praxis?

Kontakt: sagheby@htw-berlin.de

Zwei belastbare Stoßrichtungen für KI in der GA

1. Diagnose und Wartung

2. Lernende Regelung unter klaren Guardrails

KI in der Gebäudeautomation ist dann wertvoll, wenn sie vorhandene Betriebsdaten in priorisierte Entscheidungen übersetzt und mögliche Zielkonflikte transparent und kontrolliert optimiert.