



PhD-FSTM-2024-093  
Fakultät für Naturwissenschaften, Technologie und Medizin

## DISSERTATION

verteidigt am 06/12/2024 in Luxemburg

zur Erlangung des Titels

# DOCTEUR DE L'UNIVERSITÉ DU LUXEMBOURG EN SCIENCES DE L'INGÉNIEUR

von

**Sebastian Dietz**

geboren am 11. Juni 1982 in Trier (Deutschland)

## AUTOMATISIERTE FEHLERERKENNUNG UND -DIAGNOSE FÜR DEN BETRIEB VON RAUMLUFTTECHNISCHEN ANLAGEN DURCH DEN EINSATZ KÜNSTLICHER INTELLIGENZ

### Prüfungskommission

Dr.-Ing. Frank SCHOLZEN, Betreuer der Doktorarbeit  
*Professor, Universität Luxemburg*

Dr.-Ing. Holger VOOS, Vorsitzender  
*Professor, Universität Luxemburg*

Dr.-Ing. Cédric DOCKENDORF, Stellvertretender Vorsitzender  
*Professor, Universität Luxemburg*

Dr. rer. nat. Lilli FRISON  
*Fraunhofer-Institut für Solare Energiesysteme ISE*

Dr.-Ing Friedrich Sick  
*Professor, Hochschule für Technik und Wirtschaft Berlin*



## Abstract

Automated fault detection and diagnosis (FDD) methods in building systems can effectively identify operational faults, thereby improving energy efficiency and occupant comfort. However, FDD systems are rarely implemented in practice due to their high implementation effort. This work develops a method for automated FDD of air handling units (AHU) using machine learning (ML) techniques to reduce the complexity of parameterization and improve transferability.

The proposed residual-generating approach involves multi-layer perceptron (MLP) neural networks (NN) and Bayesian optimization for hyperparameter tuning to estimate the nominal, fault-free behaviour of AHU systems. Residuals from the observed data provide information about the faults for FDD. A key advantage of this approach is that readily available, fault-free data from historical operations can be used for training. By modelling the data points individually, the system automatically adapts to specific conditions and can be applied by non-ML experts.

The method's performance was evaluated in 17 case studies using real operational data from three different buildings. The results show that the approach generally provides good estimates, but the accuracy depends on the specific operational behaviour of the AHU systems. In particular, the control strategy and the number of possible operating modes influence the estimation quality.

To improve fault detection, a scoring method for residual evaluation was developed, which uses a variable tolerance band. It adjusts to the system's operating mode and reduces false alarms caused by model uncertainties, while maintaining high sensitivity in well-learned operating modes. Additionally, the residuals are normalized in fault-prone ranges through scoring, allowing the calculation of an overall score for threshold-based fault detection that accounts for the significance of individual residuals.

A decision tree approach was used for fault isolation, which assigns fault patterns in the residuals to specific fault types with high accuracy. However, a key limiting factor is the availability of historical faulty operation data required for training. It was demonstrated that systems with identical configurations exhibit similar fault patterns, indicating potential for transfer learning processes.

The developed method presents a promising approach to improving FDD in building systems and offers new opportunities for maintenance planning in facility management.



## Abstrakt

Automatisierte Methoden zur Fehlererkennung und -diagnose (FED) in gebäudetechnischen Anlagen können Betriebsfehler frühzeitig erkennen und dadurch die Energieeffizienz sowie den Raumkomfort verbessern. Allerdings werden FED-Systeme in der Praxis aufgrund des hohen Implementierungsaufwands selten eingesetzt. In dieser Arbeit wird eine Methode für die automatisierte FED von raumluftechnischen Anlagen (RLT) unter Verwendung von Verfahren des maschinellen Lernens (ML) entwickelt, um die Komplexität der Parametrisierung zu reduzieren und die Übertragbarkeit zu verbessern.

Der verfolgte Residuen-generierende Ansatz nutzt Multi-Layer-Perceptron (MLP) Neuronale Netze (NN) und eine Bayes'sche Optimierung zur Hyperparameter-Anpassung, um das nominale, fehlerfreie Verhalten von RLT-Anlagen zu schätzen. Residuen vom beobachteten Verhalten liefern Informationen über die Fehlerzustände und bilden die Grundlage für die FED. Ein wesentlicher Vorteil dieses Ansatzes besteht darin, dass gut verfügbare, fehlerfreie Daten aus dem historischen Betrieb für das Training verwendet werden können. Durch eine individuelle Modellierung der erfassten Datenpunkte passt sich das System automatisch an die spezifischen Bedingungen an und kann auch von Personen ohne ML-Expertise implementiert werden.

Die Leistungsfähigkeit der Methode wurde in 17 Fallstudien untersucht, bei denen reale Betriebsdaten aus drei verschiedenen Gebäuden verwendet wurden. Die Ergebnisse zeigen, dass der Ansatz im Allgemeinen gute Schätzungen liefert, die Genauigkeit jedoch vom spezifischen Betriebsverhalten der RLT-Anlagen abhängt. Insbesondere die Regelstrategie und die Anzahl der möglichen Betriebsmodi beeinflussen die Schätzqualität.

Zur Verbesserung der Fehlererkennung wurde eine Scoring-Methode zur Residuen-Evaluierung entwickelt, die ein variables Toleranzband nutzt. Dieses passt sich an den jeweiligen Betriebsmodus der Anlage an und reduziert Fehlalarme, die durch Modellunsicherheiten verursacht werden, während die Sensitivität in gut erlernten Betriebsmodi hoch bleibt. Zusätzlich werden die Residuen in fehleranfälligen Bereichen durch Scoring normalisiert, was die Berechnung eines aussagekräftigen Gesamtscores für eine grenzwertbasierte Fehlererkennung ermöglicht, der die Signifikanz der einzelnen Residuen berücksichtigt.

Für die Fehlerisolierung wurde ein Ansatz basierend auf Entscheidungsbäumen verwendet, der den Fehler in den Residuen bestimmten Fehlertypen mit hoher Genauigkeit zuordnet. Ein wesentlicher limitierender Faktor ist jedoch die Verfügbarkeit historischer Daten über fehlerhafte Betriebszustände, die für das Training erforderlich sind. Es wurde gezeigt, dass Systeme mit identischer Konfiguration ähnliche Fehlermuster aufweisen, was das Potenzial für transferbasiertes Lernen aufzeigt.

Die entwickelte Methode stellt einen vielversprechenden Ansatz zur Verbesserung der FED in gebäudetechnischen Anlagen dar und bietet neue Möglichkeiten für die Planung von Wartungsarbeiten im Facility Management.

## Danksagung

Ich möchte die Gelegenheit nutzen, um meinen aufrichtigen Dank an all die Menschen auszusprechen, die mich auf meinem Weg zur Fertigstellung dieser Dissertation unterstützt haben. Ohne ihre Unterstützung und Ermutigung wäre dieses Projekt nicht möglich gewesen.

Zuerst möchte ich meinem Doktorvater Prof. Frank Scholzen danken, der mir die Möglichkeit und die Freiheit gegeben hat an dem Thema dieser Dissertation zu arbeiten. Seine Ratschläge, Geduld, Orientierung und sein Engagement haben mir geholfen, mein Forschungsprojekt erfolgreich abzuschließen.

Des Weiteren möchte ich Cédric Dockendorf von Symvio S.à.r.l sowie Nicolas Réhault, Lilli Frison und der gesamten Arbeitsgruppe am Fraunhofer Institut für Solare Energiesysteme (ISE) danken. Mit Ihrem regelmäßigen fachlichen Austausch während meiner Promotionszeit haben sie mich maßgeblich unterstützt. Ihre Einblicke, Diskussionen und konstruktiven Kritiken haben meine Arbeit entscheidend geprägt.

Prof. Holger Voos möchte ich für seinen fachlichen Blick von außen sowie seine wissenschaftliche Einordnung und Expertise zu meiner Arbeit danken. Seine Anregungen haben mir entscheidend geholfen die Inhalte zu strukturieren.

Hervorheben möchte ich auch den Fond Belval (in Person von Guy Spenner), A+P Kieffer (in Person von David Kieffer) und die Hochschule für Technik und Wirtschaft (HTW) Berlin (in Person von Prof. Friedrich Sick), die großzügigerweise Betriebsdaten aus verschiedenen Gebäuden zur Verfügung gestellt haben. Diese wertvollen Daten bildeten das Fundament meiner Untersuchungen und trugen maßgeblich zum Gelingen dieser Dissertation bei.

Meinen Freunden und Kommilitonen (insbesondere Branca und Khatereh) danke ich für die moralische Unterstützung und die vertrauensvolle Zusammenarbeit. Die gemeinsamen Höhen und Tiefen, die wir in dieser Zeit erlebt haben, haben die Promotionszeit für mich umso bedeutungsvoller gemacht.

Nicht zuletzt möchte ich meiner wundervollen Frau und meinen beiden großartigen Töchtern danken, die mir insbesondere in Momenten des Zweifels eine wichtige Stütze waren. Während dieser langen, intensiven Zeit ist es mir nicht immer gelungen, ihnen die Aufmerksamkeit und Zuneigung zu schenken, wie ich es gewünscht habe. Dennoch haben sie mir mit ihrer Liebe stets das Selbstvertrauen für diesen Weg gegeben. Ohne ihre Geduld wäre diese Arbeit nicht möglich gewesen. Ebenso gilt mein tiefster

## Danksagung

---

Dank meinen Eltern, die mich mein Leben lang in all meinen Entscheidungen unterstützen und mir stets ihr Vertrauen geschenkt haben.

Diese Arbeit entstand in einer Zeit, in der die Menschheit durch protektionistisches Handeln, globale Krisen – allen voran der Klimawandel –, zunehmende militärische Konflikte und einen unmenschlichen Umgang mit Flüchtlingen immer weiter auseinanderdriftet. Vor diesem Hintergrund möchte ich von tiefstem Herzen dem (kleinen, privilegierten) Frieden danken, in dem meine Kinder aufwachsen dürfen. Mein Dank gilt auch all jenen, die mit Liebe und Mitgefühl die Welt bereichern.

Sebastian Dietz



## Inhaltsverzeichnis

Abstract.....	III
Abstrakt.....	V
Danksagung.....	VII
Inhaltsverzeichnis.....	IX
Abkürzungsverzeichnis .....	XIII
Symbolverzeichnis .....	XV
Abbildungsverzeichnis.....	XIX
Tabellenverzeichnis.....	XXV
1. Einführung in die Problemstellung .....	1
1.1. Motivation und Zielstellung der Arbeit .....	2
1.2. Vorgehensweise und Aufbau .....	4
2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen .....	5
2.1. Terminologie und Gliederung des FED-Prozesses.....	5
2.2. Klassifizierung von automatisierten Methoden .....	8
2.3. Residuen-generierender FED-Prozess .....	11
2.4. Künstliche Intelligenz (KI) für die FED.....	12
2.4.1. Multilayer Perceptron (MLP) .....	16
2.4.2. Generalisierung und Overfitting .....	19
2.4.3. Bayes'sche Optimierung und Hyperparameter Tuning.....	21
2.5. Verwandte FED-Ansätze in der Literatur.....	23
2.6. Abgrenzung des Referenzsystems (RLT-Anlage) .....	27
2.7. Mögliche Fehlerquellen in RLT-Anlagen .....	29
3. Entwurf einer KI-gestützten und Residuen-generierenden FED.....	33
3.1. Konzept und Gliederung des Gesamtprozesses .....	33
3.2. Vorverarbeitung der Rohdaten aus der Gebäudeautomation .....	35
3.3. Schätzung des nominalen Betriebsverhaltens.....	39
3.3.1. Aufbereitung und Auswahl der Eingangsdaten für das ML-Modell.....	40

3.3.2. Modellbildung & Hyperparameter tuning .....	43
3.4. Berechnung und Evaluierung der Residuen.....	46
3.4.1. L2-Norm basierte Fehlererkennung.....	47
3.4.2. Residuen-Scoring mit variablen Toleranzband .....	48
3.4.3. Scoring basierte Fehlererkennung .....	53
3.5. Fehlerisolation anhand typischer Residuen-Muster .....	54
3.6. Erstellung gelabelter Datensätze .....	57
3.7. Bewertung der FED-Performance.....	61
3.8. Umsetzung und verwendete Software-Tools .....	63
4. Beschreibung der Fallstudien.....	67
4.1. Grundschule Hohen Neuendorf .....	67
4.1.1. Lüftungskonzept und -technik.....	68
4.1.2. Datengrundlage.....	69
4.2. Maison du Savoir.....	72
4.2.1. Lüftungskonzept und -technik.....	73
4.2.2. Datengrundlage.....	75
4.2.3. Synthetischer Datensatz .....	77
4.3. Anonymisierte Liegenschaft.....	79
4.3.1. Lüftungskonzept und -technik.....	80
4.3.2. Datengrundlage.....	81
5. Darstellung und Analyse der Ergebnisse.....	85
5.1. Qualität der Schätzung für das nominale Betriebsverhalten.....	85
5.1.1. Voruntersuchungen zur Performance unterschiedlicher ML-Ansätzen .....	86
5.1.2. Grundschule Hohen Neuendorf.....	90
5.1.3. Maison du Savoir .....	94
5.1.4. Anonymisierte Liegenschaft .....	99
5.1.5. Einflussfaktoren auf die Schätzqualität.....	102
5.1.6. Zusammenfassung und Diskussion.....	107

5.2. Residuen-Evaluierung und Fehlererkennung .....	111
5.2.1. Herausforderungen in der Residuen-Evaluierung .....	111
5.2.2. Residuen-Scoring und variables Toleranzband .....	115
5.2.3. Grundschule Hohen Neuendorf .....	119
5.2.4. Maison du Savoir .....	122
5.2.5. Anonymisierte Liegenschaft .....	125
5.2.6. Veränderung zu einer $L_2$ -Norm basierten Fehlererkennung .....	126
5.2.7. Vergleich mit einem Experten-System .....	129
5.2.8. Zusammenfassung und Diskussion .....	133
5.3. Fehlerisolation .....	137
5.3.1. Observierte Fehlertypen in den Fallstudien .....	137
5.3.2. Ausprägung von Fehlermustern .....	140
5.3.3. Isolation typischer Fehlermuster .....	145
5.3.4. Zusammenfassung und Diskussion .....	148
6. Zusammenfassung und Ausblick .....	151
6.1. Zentrale Ergebnisse .....	151
6.2. Zukünftige Forschungsarbeiten .....	154
Literatur .....	157
Liste der Veröffentlichungen .....	161
Anhang .....	162



## Abkürzungsverzeichnis

ADK	Adiabate Kühlung
API	Programmierschnittstelle (engl. application programming interface)
EBC	Energy in Buildings and Communities
EPBD	Energy Performance of Building Directive
EU	Europäische Union
FAR	Fehlalarmrate (engl.: false alarm rate)
FDD	Engl. für FED (Fault Detection and Diagnosis)
FDR	Fehlererkennungsrate (engl.: fault detection rate)
FE	Fehlererkennung
FED	Fehlererkennung und -diagnose
FED&E	Fehlererkennung, -diagnose, -erkennung und -evaluierung
FI	Fehlerisolation
FM	Facility Management
FS	Fehlerstatus
FTS	Fehlertypstatus
GA	Gebäudeautomation
GLT	Gebäudeleittechnik
GSHN	Grundschule Hohen Neuendorf
HDF	Hierarchical Data Format
HLK	Heizungs-, Lüftungs- und Klimatechnik
HR	Heizregister
HVAC	Heating, Ventilation and Airconditioning
ID	Identifizierungsnummer
IEA	International Energy Agency
ISE	Fraunhofer Institut für Solare Energiesysteme
KI	Künstliche Intelligenz
KPI	Performance-Indikator (engl. key performance indicator)
nMEA	Normalisierter mittlerer absolute Fehler (engl. normalised mean absolute error)
MAE	Mittlerer absolute Fehler (engl. mean absolute error)
MSE	Mittlere quadratischer Fehler (engl. mean squared error)
ML	Maschinelles Lernen
MLP	Mehrschichtiges Perzeptron (entl. Multi-Layer Perceptron)

## Abkürzungsverzeichnis

---

MSA	Maison du Savoir
NaN	Kein gültiger Zahlenwert (engl.: not a number)
NN	Neuronales Netz
RLT	Raumluftechnische Anlagen
RMSE	Wurzel der mittleren quadratischen Abweichung (engl. root mean squared error)
TGA	Technische Gebäudeausrüstung
VK	Verteilkreis
WE	Wärmeerzeugung
WRG	Wärmerückgewinnung
WRG	Wärmerückgewinnung
WSP	Wärmespeicherung
WÜ	Wärmeübertrager

## Symbolverzeichnis

### Lateinische Symbole

$b_j^l$	Bias des Neurons $j$ in der Schicht $l$ eines NN
$CR$	Klassifizierungsrate (engl.: classification rate)
$d(t)$	Störungen
$f$	Skalierungsfaktor
$f(t)$	Fehlereinfluss
$f_{FT,Train}$	Anteil eines Fehlertyps an den Trainingsdaten
$F_n$	Werte-Anzahl falsch negativ
$F_{n,i,j}$	Werte-Anzahl falsch negativ der Fehlerklasse $i$ in der geschätzten Fehlerklasse $j$
$F_p$	Werte-Anzahl falsch positiv
$F_{p,i,j}$	Werte-Anzahl falsch positiv der Fehlerklasse $i$ in der geschätzten Fehlerklasse $j$
$FAR$	Fehlalarmrate (engl. false alarm rate)
$FE$	Fehlererkennungsalarm
$FI$	Fehlerisolation
$FIR$	Fehlerisolutionsrate (engl. fault isolation rate)
$FS$	Fehlerstatus
$FSI$	Fehlersignal
$FTS$	Fehlertypstatus
$\vec{h}_i$	Ergebnisvektor des Hidden-Layers $i$ eines NN
$i$	Laufvariable / Anzahl
$j$	Laufvariable / Anzahl
$k$	Perzentil Nummerierung
$l$	Perzentil-Rang-Position (unten/oben)
$J_{th}$	Grenzwert
$J_{th,s}$	Schwellwert für die Fehlererkennung
$m$	Laufvariable, Anzahl
$MAE$	Mittlerer absolute Fehler (engl. mean absolute error)
$MisCR$	Fehlklassifizierungsrate (engl. misclassification rate)
$MSE$	Mittlere quadratische Abweichung (engl. mean squared error)
$n$	Laufvariable, Anzahl
$N$	Gesamtanzahl der Auswertungen

## Symbolverzeichnis

---

$N_c$	Anzahl der Fehlertypen
$n_{Test}$	Anzahl der Testdaten
$n_{Train}$	Anzahl der Trainingsdaten
$n_{Val}$	Anzahl der Validierungsdaten
$nMAE$	Normalisierter mittlerer absolute Fehler (englisch: normalised mean absolute error)
$P_{ABL,Sens}$	Kanaldruck in der Abluft (Sensor)
$P_{ABL,Ven}$	Kanaldruck in der Abluft (Ventilator)
$p_i$	Perzentil $i$
$p_j(t)$	Geschätzter (codierter) Wert der $j$ -ten Klasse zum Zeitpunkt $t$
$p_{k,l}$	Perzentil $k$ an Position $l$
$p_{k,l,eval}$	Perzentil $k$ an Position $l$ im Evaluierungszeitraum
$p_{k,l,train}$	Perzentil $k$ an Position $l$ im Trainingszeitraum
$q_j(t)$	Observierter (codierter) Wert der $j$ -ten Klasse zum Zeitpunkt $t$
$r$	Residuum
$rF_{ABL}$	Relative Feuchte der Abluft
$rF_{ZUL}$	Relative Feuchte der Zuluft
$RMSE$	Wurzel der mittleren quadratischen Abweichung (englisch: root mean squared error)
$\vec{r}(t)$	Residuen-Vektor zum Zeitpunkt $t$
$\ \vec{r}(t)\ _2$	L2-Norm des Residuen-Vektors
$s$	Score
$s_{k,l}$	Score-Wert von Perzentil $k$ an Position $l$
$s_i(t)$	Score-Wert der Schätzgröße $i$ zum Zeitpunkt $t$
$t$	Zeitpunkt
$T_{ABL}$	Ablufttemperatur
$T_{AUL}$	Außenlufttemperatur
$T_{FOL}$	Fortlufttemperatur
$T_{HR,hyd,RL}$	Rücklauftemperatur im hydraulischen Kreislauf des Heizregisters
$T_{HR,hyd,VL}$	Vorlauftemperatur im hydraulischen Kreislauf des Heizregisters
$T_n$	Werte-Anzahl richtig negativ
$T_p$	Werte-Anzahl richtig positiv
$T_{p,0}$	Werte-Anzahl richtig positiv der fehlerfreien Klasse



---

$T_{p,i}$	Werte-Anzahl richtig positiv der Fehlerklasse $i$
$T_{Raum}$	Raumlufttemperatur
$T_{ZUL}$	Zulufttemperatur
$T_{ZUL,nWRG}$	Zulufttemperatur nach der Wärmerückgewinnung
$U_{ABL-Ven}$	Stellsignal des Abluftventilators
$U_{ADK,Pu}$	Stellsignal für die Pumpe der adiabaten Kühlung
$U_{HR,Ventil}$	Stellsignal des Heizregisterventils
$U_{Umluft}$	Stellsignal der Umluftklappe
$U_{WRG}$	Stellsignal der Wärmerückgewinnung
$U_{ZUL-Ven}$	Stellsignal des Zuluftventilators
$u(t)$	Stellgröße zum Zeitpunkt $t$
$\hat{u}_i(t)$	Schätzung der Stellgröße $i$ zum Zeitpunkt $t$
$\tilde{u}_w(t)$	Stellgrößenvektor ohne das $i$ -te Element (gleitendes Zeitfenster)
$\dot{V}$	Volumenstrom
$\dot{V}_{ABL}$	Abluftvolumenstrom
$\dot{V}_{ZUL}$	Zuluftvolumenstrom
$v(t)$	Zustandsgröße zum Zeitpunkt $t$
$\hat{v}_i(t)$	Schätzung der Zustandsgröße $i$ zum Zeitpunkt $t$
$\tilde{v}_w(t)$	Zustandsgrößenvektor (gleitendes Zeitfenster) zum Zeitpunkt $t$
$\tilde{v}_w(t)$	Zustandsgrößenvektor ohne das $i$ -te Element (gleitendes Zeitfenster) zum Zeitpunkt $t$
$w_{j,i}^{(l)}$	Gewicht der Verbindung vom Neuron $i$ in der Schicht $l-1$ eines NN
$\vec{w}_j^T$	Gewichtsvektor des Neurons $j$ im Hidden-Layer $l$ eines NN
$\vec{x}$	Vektor
$x_i$	Element eines Vektors $i$
$x_i^{l-1}$	Ausgabe des Neurons $i$ in der Schicht $l-1$
$\vec{x}^{(l-1)}$	Ergebnisvektor des Hidden-Layer $l-1$ eines NN
$x_{train}$	Zeitreihe einer Variable für den Trainingszeitraum
$x(t)$	Eingangsgröße / Interne Zustandsgröße
$\vec{x}_w(t_j)$	Gleitendes Zeitfenster zum Zeitpunkt $t_j$
$y_j^{(l)}$	Ergebnis des Neurons $j$ im Hidden-Layer $l$ eines NN
$z_j^{(l)}$	Gewichtete Summe des Neurons $j$ im Hidden-Layer $l$ eines NN

---

## Symbolverzeichnis

---

$y(t)$	Ausgangsgröße, observierte Zustandsgröße, Regelgröße
$\hat{y}(t)$	Schätzwert zum Zeitpunkt $t$
$\vec{\hat{y}}(t)$	Schätzvektor zum Zeitpunkt $t$

### Griechische Symbole

$\sigma(x)$	Aktivierungsfunktion eines neuronalen Netzes
$\theta$	Prozessparameter

## Abbildungsverzeichnis

Abbildung 1: Teilschritte n der Fehlererkennung (FE), -diagnose (FED) und Evaluierung (FED&E) (In Anlehnung an [16] und [15]).	7
Abbildung 2: Kategorisierung unterschiedlicher FED-Methoden (in Anlehnung an [18]).	8
Abbildung 3: Klassifizierung modellbasierter FED-Ansätze.	9
Abbildung 4: Residuen-generierender FED-Prozess (in Anlehnung an [13]).	11
Abbildung 5: Struktur eines MLP-Netzwerkes mit n Inputs und einem Output. Eigene Darstellung in Anlehnung an [23].	17
Abbildung 6: Unterschiedliche Aktivierungsfunktionen von neuronalen Netzen. Das dargestellte Beispiel für die Softmax-Funktion zeigt das Resultat für drei möglichen Klassen.	18
Abbildung 7: Exemplarische Verläufe für die Trainings- und Validierungsverluste in Abhängigkeit von der Anzahl Iterationen.	20
Abbildung 8: Gliederung der Betriebsdaten in Trainings-, Validierungs- und Testzeiträume.	20
Abbildung 9: Beispielhafte Gliederung eines HLK-Systems in die Teilkomponenten Wärmeerzeugung (WE), Wärmespeicherung (WSP), Verteilkreise (VK), Wärmeübertragung (WÜ), thermische Zone und raumluftechnische Anlage (RLT). Die rot gestrichelte Linie zeigt die Grenze für das gewählte Referenzsystem.	28
Abbildung 10: Strukturelle Zerlegung eines Systems und mögliche Quellen von Fehlern.	29
Abbildung 11: Prozessschritte im Residuen-generierenden FED-Entwurf.	34
Abbildung 12: Standardisierte Datenpunktbezeichnungen eines Projektes (links) und Mapping mit einem Systemtemplate für eine RLT-Anlage (rechts).	37
Abbildung 13: Beispiel für die Interpolation von Betriebsdaten bei häufigen kurzzeitigen Datenlücken.	38
Abbildung 14: Schema für die Transformation der Zeitreihen in ein gleitendes Zeitfenster.	42
Abbildung 15: Konzeptionelle Darstellung für die Konstruktion des Schätzvektors der Stell- und Zustandsgrößen des observierten Systems.	44
Abbildung 16: Prozessdiagramm für die Evaluierung der Residuen.	48
Abbildung 17: Histogramm für die Residuen der Ablufttemperatur im Frischluftbetrieb (MSA, AUD-7, Testzeitraum) für fehlerhafte (rot) und fehlerfreie Datensätze (blau). Die grau gepunkteten Linien zeigen die Perzentile, die für das linearisierte Scoring (rote Linie) verwendet wurden.	50
Abbildung 18: Beispiel für das linearisierte Scoring der Residuen anhand des zeitlichen Verlaufs des Stellsignals für die WRG der RLT-Anlage AUD7 im MSA-Gebäude.	52
Abbildung 19: Zeitreihenbeispiel der implementierten Fehlererkennung auf Basis des Scoring-Verfahrens. Dargestellt ist ein Umluftbetrieb der RLT-Anlage AUD7 im MSA-Gebäude ohne aktivierte Heizung oder Kühlung.	53
Abbildung 20: Box-Plot-Darstellung für die berechneten Residuen im Fehlerfall. Dargestellt ist das Fehlermuster für den Betrieb mit einem geöffneten Heizregisterventil ohne eine Erwärmung der Zuluft (RLT-Anlage FLA, GSHN-Gebäude).	55

## Abbildungsverzeichnis

---

Abbildung 21: Prozessdiagramm für das Trainieren und das Anwenden von klassifizierenden Modellen zur Fehlerisolation auf Basis der Residuen-Muster. ....	56
Abbildung 22: Schema für die eingesetzten Methoden zum Kennzeichnen (Labeln) der Datensätze hinsichtlich des Fehlerzustandes und des vorliegenden Fehlertyps zur Bewertung der Ergebnisse des entwickelten FED-Ansatzes. ....	60
Abbildung 23: Programmstruktur für die entwickelten Python-Module zur Umsetzung des Residuen-generierenden FED-Ansatzes. ....	65
Abbildung 24: Südwestansicht der Grundschule Hohen Neuendorf [57]. ....	67
Abbildung 25: Anlagenschema mit einer standardisierten Kennzeichnung der erfassten Datenpunkte für die Lüftungsanlagen FLA, FLB, FLC, FA und SPO in der Grundschule Hohen Neuendorf (GSHN). ....	70
Abbildung 26: Anteile der Betriebsmodi für die RLT-Anlage FLB im GSHN-Gebäude an den Datensätzen für das Training, die Validierung und das Testen. ....	71
Abbildung 27: Anteile der Betriebsmodi für die RLT-Anlage SPO im GSHN-Gebäude an den Datensätzen für das Training, die Validierung und das Testen. ....	72
Abbildung 28: Außenansicht (links) und Innenansicht eines Hörsaals (rechts) für das Maison du Savoir der Universität Luxembourg. [Bildquelle: Baumschlager Eberle, <a href="http://www.archphoto.com">www.archphoto.com</a> , 14.03.2024]. ....	72
Abbildung 29: Anlagenschema mit einer standardisierten Kennzeichnung der erfassten Datenpunkte für die mechanische Lüftungsanlage der Hörsäle im Maison du Savoir (MSA). ...	74
Abbildung 30: Ansicht einer RLT-Anlage im Maison du Savoir (links) und Detailfoto vom hydraulischen Anschluss des Heizregisters. ....	75
Abbildung 31: Anteile der Betriebsmodi für die RLT-Anlage AUD8 im MSA-Gebäude an den Datensätzen für das Training, die Validierung und das Testen. ....	77
Abbildung 32: Anteile der Betriebsmodi für die RLT-Anlage AUD9 im MSA-Gebäude an den Datensätzen für das Training, die Validierung und das Testen. ....	77
Abbildung 33: Schematische Darstellung des in der Programmumgebung TRNSYS umgesetzten dynamischen Simulationsmodells für die RLT-Anlage AUD8 im MSA-Gebäude. ....	78
Abbildung 34: Anlagenschema mit einer standardisierten Kennzeichnung der erfassten Datenpunkte für die Lüftungsanlage des Theatersaals (CTA02) in der anonymisierten Liegenschaft (ISC). ....	80
Abbildung 35: Anteile der Betriebsmodi für die RLT-Anlage CTA02 im ISC-Gebäude an den Datensätzen für das Training, die Validierung und das Testen. ....	82
Abbildung 36: Anteile der Betriebsmodi für die RLT-Anlage CTA08 im ISC-Gebäude an den Datensätzen für das Training, die Validierung und das Testen. ....	83
Abbildung 37: Metriken (MAE, RMSE) für unterschiedliche Modellkapazitäten eines Multi-Layer-Perceptron (MLP) Models mit ReLU-Aktivierungsfunktion zur Schätzung der Zulufttemperatur (GSHN, RLT-Anlage FLA). ....	89
Abbildung 38: Schätzungen der Zulufttemperatur (GSHN, FLA) durch unterschiedliche Modellansätze für einen Sommer- (oben) und einen Wintertag (unten). ....	90

Abbildung 39: Normalisierter MAE sowie Median für die Schätzungen kontinuierlicher Größen für den Betrieb der RLT-Geräte im GSHN-Gebäude (Testzeitraum).....	91
Abbildung 40: Exemplarische Zeitreihen der observierten und geschätzten Verläufe für das Stellsignal des Heizregisterventils ausgewählter RLT-Anlagen der GSHN.....	92
Abbildung 41: Regressionen für die Heizkurve auf Basis der Vorlauftemperatur im hydraulischen Kreislauf des Heizregisters der RLT-Anlage FLA (GSHN) für den Trainings- und Validierungszeitraum sowie den Testzeitraum. Grundlage für die Regression sind stündliche Mittelwerte der Daten im Heizbetrieb. Neben der Regressionskurve ist das Konfidenzband (95%) der Regression sowie der Mittelwerte (Punkte) über diskrete Abschnitte der x-Achse dargestellt.....	93
Abbildung 42: Exemplarische Zeitreihendarstellung der observierten und geschätzten Verläufe für die Ablufttemperatur ausgewählter RLT-Anlagen der GSHN.....	93
Abbildung 43: Normalisierte MAE sowie der Median für die Schätzungen kontinuierlicher Größen der RLT-Geräte im MSA-Gebäude (Testzeitraum).....	95
Abbildung 44: Beispielhafte Tagesverläufe im Testzeitraum für die Schätzung der Zulufttemperatur und des Stellsignals für das Heizregisterventil auf Basis des synthetischen Datensatzes.....	96
Abbildung 45: Beispielhafte Tagesverläufe im Testzeitraum für die Schätzung der Außenluftfeuchte (RLT-Anlage AUD8, MSA-Gebäude).....	97
Abbildung 46: Beispielhafte Tagesverläufe im Testzeitraum für die Schätzung der Zulufttemperatur im Heiz- und im Kühlbetrieb (RLT-Anlage AUD8, MSA-Gebäude).....	98
Abbildung 47: F1-Score sowie Median für die Schätzungen diskreter Größen der RLT-Geräte im MSA-Gebäude (Testzeitraum).....	98
Abbildung 48: Normalisierter MAE sowie der Median für die Schätzungen kontinuierlicher Größen der RLT-Geräte im ISC-Gebäude (Testzeitraum).....	100
Abbildung 49: Exemplarischer Tagesverlauf der Schätzgröße $U_{ABL} - Ven$ (Stellsignal Ventilator) für die Anlagen CTA01 und CTA03.....	100
Abbildung 50: Liniendiagramm für den Druck im Abluftkanal erfasst durch einen Sensor (rot) und die Ventilatorsteuerung (blau). Dargestellt ist der jährliche Median im eingeschalteten Zustand der Anlage.....	101
Abbildung 51: F1-Score sowie der Median für die Schätzungen diskreter Größen der RLT-Geräte im ISC-Gebäude (Testzeitraum).....	102
Abbildung 52: Veränderung des Medians für den normalisierten absoluten Fehler (nMAE) durch das Filtern fehlerhafter Betriebszustände in den Trainingsdaten der untersuchten Fallstudien.....	104
Abbildung 53: Relative Häufigkeitsverteilung im Fehlerfall für die Residuen-Beträge der Systemgrößen $T_{ZUL,nWRG}$ und $U_{Umluft}$ der RLT-Anlage AUD7 im MSA-Gebäude. Dargestellt sind die Ergebnisse ohne eine Filterung der fehlerhaften Betriebszustände für das Modelltraining (blau) und mit einer Filterung (rot).....	104
Abbildung 54: Mittelwert des normalisierten Fehlers für alle Schätzgrößen der Anlage FLA im GSHN-Gebäude für unterschiedliche Trainingszeiträume. Die vertikalen Linien markieren den	

## Abbildungsverzeichnis

---

Wertebereich der individuellen Ergebnisse (oben). Im unteren Diagramm ist die Anzahl der verfügbaren Datensätze für das Training dargestellt. ....	106
Abbildung 55: Mittelwert des normalisierten Fehlers für alle Schätzgrößen der Anlage CTA17 im ISC-Gebäude für unterschiedliche Trainingszeiträume. Die vertikalen Linien markieren den Wertebereich der individuellen Ergebnisse (oben). Im unteren Diagramm ist die Anzahl der verfügbaren Datensätze für das Training dargestellt. ....	106
Abbildung 56: Säulendiagramm für die gebäudespezifischen Mittelwerte der nMAEs für die Schätzungen des nominalen Betriebsverhaltens mit und ohne Filterung der Eingangsdaten. Die eingezeichneten Linien zeigen den Wertebereich der anlagenspezifischen Mittelwerte. ....	108
Abbildung 57: Relative Häufigkeit der normierten Residuen im fehlerfreien (blau) und fehlerbehafteten Betriebszustand (rot) für die Ablufttemperatur (links) und das Stellsignal der WRG (rechts) am Beispiel der RLT-Anlage AUD7 im MSA-Gebäude. ....	112
Abbildung 58: Relative Häufigkeitsverteilung der Residuen für die Zulufttemperatur der RLT-Anlage AUD8 im MSA-Gebäude gegliedert in die Betriebsmodi Frischluftbetrieb ohne Luftbehandlung, Kühlbetrieb und Heizbetrieb. Die Grundlage sind Daten im fehlerfreien Zustand. ....	113
Abbildung 59: Zeitreihenbeispiele für ausgewählte Residuen (blau), die Betragssumme aller Residuen (gelb) und dem wahren Fehlerzustand (rot) für die RLT-Anlage AUD8 im MSA-Gebäude. ....	114
Abbildung 60: Residuen-Histogramme für das Stellsignal der WRG der RLT-Anlage AUD8 im MSA-Gebäude im fehlerfreien Betriebszustand getrennt nach dem aktuellen Betriebsmodus der Anlage. Die vertikalen Linien zeigen den Median und die Perzentile 1 bis 5 für das Scoring. .	116
Abbildung 61: Zeitreihenbeispiele (15. und 17.06.2021) für ausgewählte Residuen (blau), die Summe aller Scores (gelb) und dem wahren Fehlerzustand (rot) für die RLT-Anlage AUD8 im MSA-Gebäude. Die gestrichelten und roten Linien in den Residuen-Diagrammen zeigen die untere und obere Grenze für das Scoring der Residuen. ....	117
Abbildung 62: Zeitreihenbeispiel (25.07.2022) für ausgewählte Residuen (blau) und Scores (grau), den Gesamtscore (gelb) und dem wahren Fehlerzustand (rot) der RLT-Anlage AUD8 im MSA-Gebäude. Die gestrichelten und roten Linien in den Residuen-Diagrammen zeigen die untere und obere Grenze für das Scoring der Residuen. ....	118
Abbildung 63: Zeitreihenbeispiele für das Ergebnis der FE die Erkennung des Fehlertyps „keine Heizleistung bei geöffnetem HR-Ventil. (RLT-Anlage FLA). ....	120
Abbildung 64: Zeitreihenbeispiele für Fehlalarme aufgrund transienter Zustände infolge wechselnder Betriebsmodi (links, RLT-Anlage FLB) und ungewöhnlicher Wetterereignisse (rechts, RLT-Anlage FA). ....	121
Abbildung 65: Konfusion-Matrix für die Fehlererkennung im Testzeitraum der RLT-Anlage AUD2 im MSA-Gebäude. Angegeben sind die absoluten und relativen Anteile der Klassen am Gesamtdatensatz. Die Farbgebung der Kacheln zeigt den Anteil an der wahren Klasse ( <i>FS<sub>wahr</sub></i> ). ....	123
Abbildung 66: Exemplarische Zeitreihen ausgewählter Residuen (blau), des Gesamtscores (gelb) sowie das Ergebnis der Fehlererkennung (rot, FD) und der wahren Fehlerzustand (rot, <i>FS<sub>wahr</sub></i> ). Das linke Diagramm zeigt Fehlalarme für Anlage AUD9 aufgrund von veränderten	

Soll-Volumenströmen, während das rechte Diagramm Fehlalarme aufgrund einer Überhitzung der Nutzungszone von AUD4 veranschaulicht, .....	124
Abbildung 67: Exemplarische Zeitreihen ausgewählter Residuen (blau), des Gesamtcores (gelb) sowie das Ergebnis der Fehlererkennung (rot, FD) und der wahre Fehlerzustand (rot, $F_{\text{wahr}}$ ) für die RLT-Anlage CTA08 (ISC-Gebäude). Der wahre Fehlerzustand signalisiert eine Ventilöffnung bei abgeschalteter Pumpe im hydraulischen Kreis des Heizregisters. ....	126
Abbildung 68: Fehlalarmrate (links) und Anzahl der Alarme (rechts) für die Fehlererkennung basierend auf der L2-Norm (blau) und der Scoring-Methode (rot). Ergänzend ist die Anzahl der Alarme für den gelabelten Fehlerzustand (FS-Label, grau) dargestellt. Neben den individuellen Ergebnissen für die RLT-Anlagen (unten) zeigen die Diagramme den Median und dessen Vertrauensintervall (95%) (oben). ....	128
Abbildung 69: Fehlererkennungsrate (blau) für die Scoring-Methode (rot) und das Expertensystem (blau). Neben den individuellen Ergebnissen für die RLT-Anlagen (unten) zeigt das Diagramm den Median und das Vertrauensintervall (95%) (oben). ....	130
Abbildung 70: Exemplarische Zeitreihen für observierte Betriebsfehler und die Ergebnisse der FE. Das linke Beispiel zeigt eine Leckage des Heizregisterventils für die RLT-Anlage FLB in der GSHN, die ausschließlich durch den Residuen-generierenden Ansatz erkannt wird. En mit dem Expertensystem übereinstimmendes Ergebnis zeigt das rechte Diagramm (CTA17, ISC-Gebäude). Obwohl das Betriebssignal einen abgeschalteten Abluftventilator suggeriert und die Außenluftklappen geschlossen sind, ist ein deutlicher Überdruck zu verzeichnen. ....	131
Abbildung 71: Median der Fehleralarmrate (FAR, links) und der Fehlererkennungsrate (FDR, rechts), gruppiert nach Gebäude der untersuchten Fallstudien. ....	134
Abbildung 72: Exemplarische Darstellung der resultierenden Muster in den Scores (links) und den Residuen (rechts) für den Fehlertyp „HR-Ventil offen und keine Heizleistung“. ....	141
Abbildung 73: Entwicklung des Residuen-Musters für den Fehlertyp „Heizbetrieb ohne WRG“ bei zunehmender Anzahl (5,10,50,400) zufällig ausgewählter Datensätzen aus dem Betrieb der RLT-Anlage AUD8 im MSA. ....	142
Abbildung 74: Muster in den Residuen ausgewählter Fehlertypen der RLT-Anlage AUD8 im MSA-Gebäude (gesamter Auswertzeitraum). ....	143
Abbildung 75: Fehlermuster des Fehlertyps „HR-Ventil offen und keine Heizleistung“ für RLT-Anlagen mit gleicher Systemkonfiguration. ....	144
Abbildung 76: Fehlermuster des Fehlertyps „HR-Ventil offen und keine Heizleistung“ für RLT-Anlagen mit unterschiedlicher Systemkonfiguration. ....	145
Abbildung 77: Zeitreihenbeispiel der Fehlerisolation für den Fehlertyp „Heizventil geöffnet und keine Erwärmung der Zuluft“ im Betrieb der RLT-Anlagen FLA im GSHN-Gebäude. ....	146
Abbildung 78: Zeitreihenbeispiel der Fehlerisolation für die RLT-Anlage AUD8 im MSA-Gebäude. Die Isolation erfolgt für die Fehlertypen „Umluftbetrieb ohne Heizen oder Kühlen“ (Typ 1) und „Heizbetrieb ohne Wärmerückgewinnung“ (Typ 2). ....	148
Abbildung 79: Konzept für die kombinierte Anwendung einer regelbasierten FE (Expertensystem) mit dem entwickelten Residuen-generierenden Ansatz. ....	155





## Tabellenverzeichnis

Tabelle 1: Klassifizierung von FED-Systemen hinsichtlich ihrer architektonischen Struktur sowie deren Vor- und Nachteile in der Anwendung [15]. .....	10
Tabelle 2: Übersicht typischer ML-Methoden aus dem Bereich des Supervised Learnings. Extrahiert aus [23], [24]. Aufgrund ihrer weiten Verbreitung im deutschsprachigen Raum sind die englischen Bezeichnungen der Methoden aufgeführt. ....	14
Tabelle 3: Unterschiedliche Optimierungsmethoden für das Tunen von Hyperparametern im Bereich des maschinellen Lernens. Die Kategorisierung erfolgt in Anlehnung an [30]. .....	22
Tabelle 4: Auswahl bedeutender und aktueller Review-Veröffentlichungen zum Thema Fehlererkennung und Diagnose in gebäudetechnischen Anlagen. Aktualisiert auf Basis von [15]. ....	24
Tabelle 5: Ausgewählte Veröffentlichungen mit Residuen-Generierenden FED-Ansätzen für gebäudetechnischen Anlagen, die eingesetzten KI-Methoden und verwendete Datengrundlage .....	26
Tabelle 6: Schritte in der Vorverarbeitung der Rohdaten aus der Gebäudeautomation. ....	37
Tabelle 7: Gewählte Hyperparameters für das Trainieren der MLP. Parameter, für die ein Wertebereich angegeben ist, werden durch eine Bayes'sche-Optimierung gefunden. ....	45
Tabelle 8: Verwendete Perzentile, deren Rang und zugewiesene Score-Werte. ....	50
Tabelle 9: Gewählte Hyperparameter für das Trainieren der Random-Forest Klassifikatoren zur Fehlerisolation. Parameter, für die ein Wertebereich angegeben ist, werden durch eine Rastersuche gefunden. ....	57
Tabelle 10: Übersicht der angewendeten Methoden zum Labeln der Datensätze der untersuchten Fallstudien. ....	60
Tabelle 11: Verwendete Python-Bibliotheken sowie deren Versionsnummer und Anwendungsgebiet. ....	64
Tabelle 13: Akronyme, Versorgungszonen und Eigenschaften der RLT-Anlagen in der Grundschule Hohen Neuendorf. ....	69
Tabelle 14: Nennvolumenströme und Luftbehandlungsfunktionen der RLT-Anlagen im Maison du Savoir. ....	73
Tabelle 15: Nennvolumenströme und Luftbehandlungsfunktionen der RLT-Anlagen im ISC-Gebäude. ....	81
Tabelle 16: Metriken für unterschiedliche Modellansätze zur Schätzung der Zulufttemperatur. Die Berechnung der Metriken erfolgte auf Basis des Trainings- und Validierungszeitraumes. ...	86
Tabelle 17: Ergebnisse für den Modelltyp „Light Gradient Boosting Machine“ bei einer Schätzung basierend auf dem Testdatensatz. ....	89
Tabelle 18: Mittelwerte der normalisierten MAE je Auswertezeitraum für die Schätzungen der RLT-Anlagen im GSHN-Gebäude. ....	94
Tabelle 19: Mittelwerte der normalisierten MAE je Auswertezeitraum für die Schätzungen der RLT-Anlagen im GSHN-Gebäude. ....	95

## Tabellenverzeichnis

---

Tabelle 20: Mittelwerte des normalisierten MAE je Auswertezeitraum für die Schätzungen der RLT-Anlagen im ISC-Gebäude. ....	100
Tabelle 21: Anteile fehlerhafter Betriebszustände in den Test-Datensätzen der RLT-Anlagen in der GSHN sowie die ermittelten Metriken der Fehlererkennung. ....	119
Tabelle 22: Anteile fehlerhafter Betriebszustände in den Test-Datensätzen der RLT-Anlagen im Maison du Savoir sowie die ermittelten Metriken der Fehlererkennung. ....	122
Tabelle 23: Anteile fehlerhafter Betriebszustände in den Test-Datensätzen der RLT-Anlagen in der anonymisierten Liegenschaft sowie die ermittelten Metriken der Fehlererkennung. ....	125
Tabelle 24: Observierte Fehlertypen und deren Anteile an den fehlerbehafteten Daten der Fallstudien im GSHN-Gebäude. ....	138
Tabelle 25: Observierte Fehlertypen und deren Anteile an den fehlerbehafteten Daten der Fallstudien im ISC-Gebäude. ....	138
Tabelle 26: Observierte Fehlertypen und deren Anteile an den fehlerbehafteten Daten der Fallstudien im MSA-Gebäude. ....	139
Tabelle 27: Ergebnisse der Fehlerisolation für den Fehlertyp „Heizventil geöffnet und keine Erwärmung der Zuluft“ im Betrieb der RLT-Anlagen im GSHN-Gebäude. Die dargestellten Metriken beziehen sich auf den Testzeitraum. ....	146
Tabelle 28: Ergebnisse der Fehlerisolation für den Fehlertyp „Heizventil geöffnet und keine Erwärmung der Zuluft“ im Betrieb der RLT-Anlagen im GSHN-Gebäude. Die dargestellten Metriken beziehen sich auf den Testzeitraum. ....	147

### 1. Einführung in die Problemstellung

Der Gebäudebestand in der Europäischen Union (EU) ist für ca. 40% unseres Energieverbrauchs und 36% der Treibhausgasemissionen verantwortlich, die durch Bau, Nutzung, Renovierung und Abriss verursacht werden [1]. Der Verbesserung der Energieeffizienz von Gebäuden kommt daher eine Schlüsselrolle zum Erreichen der Klimaneutralität bis 2050 zu (European Green Deal) [2].

Gleichzeitig werden etwa 75% des EU-Gebäudebestandes nach dem heutigen Stand der Technik ineffizient betrieben [1]. Dabei können bereits geringinvestive Maßnahmen signifikante Effizienzsteigerungen erzielen. In gewerblich genutzten Gebäuden verursachen Fehler im Gebäudebetrieb oder fehlende Wartungsarbeiten an der technischen Gebäudeausrüstung schätzungsweise 10% bis 20% [3][4] des Energieverbrauchs. Zusätzlich steigt aufgrund technologischer Entwicklungen die Komplexität der Anlagentechnik und kann vom betreuenden Fachpersonal nur selten vollständig überwacht werden. Durch den hohen personellen Aufwand für eine manuelle Erkennung und Diagnose bleibt das Einsparpotenzial häufig ungenutzt. Ein Weg den Aufwand zu reduzieren ist die Einführung einer flächendeckenden, automatisierten Zustands- und Fehlererkennung sowie einer anschließenden Diagnose (FED, engl.: Fault Detection and Diagnosis, FDD) und das Aufbereiten von Handlungsempfehlungen für den Gebäudebetreiber [5].

In der Praxis werden im Gebäudesektor jedoch nur selten automatisierte FED-Methoden eingesetzt [6]. Dabei zeigen Feldstudien, dass sie helfen einen energieeffizienten Betrieb von gebäudetechnischen Anlagen dauerhaft sicherzustellen. Mittlere Energieeinsparungen von 10% wurden in mehreren Pilotprojekten demonstriert [7]. Gleichzeitig erhöht eine frühzeitige Erkennung von unerwünschten Betriebszuständen den thermischen Raumkomfort. Doch nicht nur die Nutzerzufriedenheit kann durch FED-Methoden gesteigert werden, auch im Bereich des Facility Managements (FM) werden durch eine zustandsorientierte Wartung neue, kosteneffizientere Wege hinsichtlich der Personalplanung ermöglicht.

Ein wesentliches Hemmnis ist der geringe Anteil der Energiekosten an den gesamten Lebenszykluskosten eines Gebäudes und damit verbunden ein, relativ betrachtet, geringer Kosteneinsparpotential für energieeffizienzsteigernde Maßnahmen im Betrieb. Beispielsweise verantworten in einem Bürogebäude die Nutzungskosten, mit einem Anteil von ca. 75%, zwar einen Großteil der Gesamtkosten, jedoch werden hiervon nur ca. 15% durch Energiedienstleistungen verursacht [8]. Die Energiekosten haben daher

## 1. Einführung in die Problemstellung

---

in der Gesamtkostenreduktion eine untergeordnete Priorität, zumal durch den Einsatz eines FED-Systems zusätzliche Kosten anfallen, die durch die Energieeinsparung kompensiert werden müssen. Aus Sicht der Anwendung ist es daher essenziell, dass der Aufwand für das Implementieren eines FED-Systems möglichst gering ist und ein hohes Maß an Übertragbarkeit gewährleistet wird. Gleichzeitig müssen Synergieeffekte genutzt werden, sodass neben einer möglichen Energieeinsparung weitere Vorteile im Bereich des FM erzielt werden.

### 1.1. Motivation und Zielstellung der Arbeit

Im Bereich der Nichtwohngebäude ist nach dem aktuellen Stand der Technik häufig eine Gebäudeleittechnik (GLT) installiert. Zudem fordert die europäische Richtlinie über die Energieeffizienz in Gebäuden (EPBD - Energy Performance of Buildings Directive) [9] und deren nationalen Umsetzung [10] den Einsatz eines GLT-Systems, wenn eine bestimmte Leistungsgrenze hinsichtlich der Anlagentechnik überschritten wird. Die aktuelle Fassung geht sogar einen Schritt weiter und führt einen Intelligenzfähigkeitsindikator für Gebäude ein. Damit wird nicht nur die Grundlage für eine flächendeckende automatisierte FED geschaffen, sondern deren Einsatz zukünftig auch positiv in der Gesamteffizienzbewertung des Gebäudes aufgenommen. In der derzeitigen Praxis erfolgt jedoch nur eine stichprobenartige manuelle Analyse der Daten im Falle von offensichtlichen Fehlfunktionen, Nutzerbeschwerden oder Alarm-Meldungen durch die GLT. Hierzu sind i.d.R. einfache Regelsätze implementiert, die wenige, grundlegenden Funktionen überprüfen, jedoch keine umfassende FED bereitstellen. Potentiale für Energieeinsparungen, Komfortsteigerungen und eine Zustandsorientierte Wartung bleiben somit ungenutzt.

Gebäude und deren Versorgungstechnik werden i.d.R. individuell designt und können im Betrieb auch bei identischen Dienstleistungen, z.B. eine mechanische Lüftung mit Heizfunktion und Wärmerückgewinnung, sehr unterschiedliche Betriebscharakteristiken zeigen. Hierfür zeichnet sich, neben der unterschiedlichen Dimensionierung der Einzelkomponenten (z.B. nominelle Leistung des Heizregisters) in Abhängigkeit der Gebäudeanforderungen, insbesondere die individuelle Programmierung der Regelung des observierten Systems verantwortlich. Die Anpassung von komplexeren automatisierten FED-Methoden, wie bspw. größere Regelsätze, an das dynamische Verhalten des Systems, erfordert entweder ein aufwändiges Feintuning der Parameter oder macht eine Neu-, bzw. Weiterentwicklung des FED-Prozesses notwendig. Dies gilt insbesondere im Bereich der modellbasierten Ansätze. Gleichzeitig ist die vorhandene

Daten-Basis von Gebäude zu Gebäude unterschiedlich. Diese Ausgangssituation fordert vom FED-System eine hohe Flexibilität und stellt somit die Entwicklung von FED-Methoden vor eine besondere Herausforderung.

Ein möglicher Ansatz zur Reduzierung des Modellierungsaufwands ist der Einsatz von Methoden aus dem Bereich des maschinellen Lernens (ML). Diese Methoden lernen das Systemverhalten anhand statistischer Zusammenhänge in den historischen Betriebsdaten. Die Qualität der Schätzungen hängt jedoch maßgeblich von den system-spezifischen Datensätzen ab. Dies erfordert ein maßgeschneidertes Design in Bezug auf die Datenverarbeitung, den Modelltyp sowie die Modellstruktur und erhöht den Bedarf an Fachkräften mit Kenntnissen im Bereich des ML sowie an Entwicklungszeit und -kosten. Insbesondere im Bereich der technischen Gebäudeausrüstung erschwert die begrenzte Übertragbarkeit von ML-Methoden die Anwendung.

Mit der Motivation den Engineering-Prozess von FED-Systemen im Gebäudebereich zu beschleunigen und damit deren Einsatz im Facility-Management oder angrenzenden Dienstleistungen zu ermöglichen, ist das wissenschaftliche und technische Arbeitsziel der vorliegenden Arbeit die Entwicklung einer allgemeingültigen, anwendungsbezogenen Systematik für eine automatisierte Fehlererkennung und -diagnose in Gebäuden auf Basis von historischen Betriebsdaten. Durch den Einsatz von ML-Methoden und einer skalierbaren Architektur des FED-Prozesses soll der individuelle Modellierungsaufwand minimiert und ein hoher Grad an Übertragbarkeit der Systematik gewährleistet werden. Letzteres erfordert insbesondere eine automatisierte Anpassung der FED an das individuelle Systemverhalten, die Anzahl verfügbarer Datenpunkte, die zeitliche Auflösung, die Datenqualität sowie die statistischen Eigenschaften der Datensätze. Hierzu werden in dieser Arbeit die generelle Eignung von ML-Methoden in einem ganzheitlichen FED-Prozess am Beispiel von raumluftechnischen Anlagen (RLT) untersucht und die Grenzen in der Anwendung aufgezeigt. Der Entwicklungsfokus liegt auf einem hohen Automatisierungsgrad im gesamten FED-Prozess, wodurch die Implementierung und Nutzung auch ohne tiefgehendes Expertenwissen im Bereich des ML ermöglicht wird.

Weitere Anforderungen an einen FED-Prozess ergeben sich aus Bedürfnissen in der praktischen Anwendung. Das Auftreten von Fehlern lässt sich insbesondere in komplexen Systemen nicht immer völlig vermeiden. Um eine hohe Akzeptanz hinsichtlich der generierten Fehlermeldungen zu erzielen, muss das FED-System gegenüber Fehlerzuständen ohne oder nur geringer Auswirkung auf das Betriebsverhalten möglichst

## 1. Einführung in die Problemstellung

---

tolerant sein und Fehlalarme müssen vermieden werden. Ferner sollte die gewählte Methodik für die Anwendung im Bereich des FM eine weiterführende Diagnose ermöglichen. Hierzu gehört insbesondere die Ermittlung des Fehlertyps und der Fehlerauswirkung. Anhand der so gewonnenen Informationen können Handlungsempfehlungen abgeleitet und eine Priorisierung in der Fehlerbehebung durchgeführt werden.

### 1.2. Vorgehensweise und Aufbau

Die vorliegende Arbeit führt zunächst die grundlegenden Terminologien im Bereich der Fehlererkennung und -diagnose ein, um anschließend die theoretischen Ansätze aus der Literatur vorzustellen und einzuordnen (Kapitel 2). Hierbei liegt der Fokus auf der Anwendung von FED-Methoden im Gebäudesektor. Zudem werden die Systemgrenzen für die Untersuchungen in dieser Arbeit definiert und mögliche Fehlerquellen in raumluftechnischen Anlagen (RLT) sowie deren Eigenschaften erläutert. Aus dem Anwendungsziel lassen sich die Anforderungen für die Entwicklung eines KI-gestützten FED-Prozesses ableiten. Die entwickelte Methodik für einen Residuen-generierende Ansatz wird in Kapitel 3 vorgestellt. Hierzu gehören, neben der Gliederung des implementierten Prozesses, auch die notwendigen Schritte zur Vorverarbeitung der Rohdaten, sowie die Schätzung des nominalen Betriebsverhaltens und die Evaluierung der berechneten Residuen für die Fehlererkennung und -diagnose. Mit dem Ziel die Performance hinsichtlich Übertragbarkeit und Qualität der FED bewerten zu können, wird die Methodik auf Datensätze mehrerer RLT-Anlagen aus drei verschiedenen Gebäuden angewendet (Beschreibung in Kapitel 4). Eine Darstellung und Analyse der Ergebnisse für die untersuchten Fallstudien hinsichtlich der Schätzqualität für das nominale Betriebsverhaltens, der Fehlererkennung und der Fehlerdiagnose erfolgt in Kapitel 5. Abschließend werden die gewonnenen Erkenntnisse zusammengefasst und daraus resultierende Fragestellungen für weiterführende wissenschaftliche Arbeiten formuliert (Kapitel 6).

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

Die Überwachung von technischen Prozessen zielt darauf ab, den Ist-Zustand des observierten Prozesses aufzuzeigen, unerwünschte oder unzulässige Zustände zu detektieren und geeignete Maßnahmen zur Vermeidung von Betriebsausfällen oder Schäden an der Anlage einzuleiten. Der Vorgang, den Anlagenzustand ohne eine zeitaufwändige manuelle Analyse durch einen Experten zu bestimmen, wird als automatisierte Fehlererkennung und -diagnose (FED) bezeichnet. In diesem Kapitel werden die grundlegende Terminologie und die Gliederung des ganzheitlichen FED-Prozesses eingeführt (Abschnitt 2.1) und existierende Ansätze in der Literatur eingeordnet (Abschnitt 2.2). Der verfolgte Ansatz einer Residuen-generierenden FED (Abschnitt 2.3) adressiert die spezifischen Anforderungen für die Anwendung in der Heizungs-, Lüftungs- und Klimatechnik (HLK). Zudem werden die für diese Arbeit notwendigen Grundlagen aus dem Bereich des maschinellen Lernens (ML) erläutert (Abschnitt 2.4) und verwandte FED-Ansätze im Bereich der HKL-Technik aus der Literatur analysiert (Abschnitt 2.5). Gebäudetechnische Anlagen lassen sich in Teilsysteme mit unterschiedlichen Funktionen gliedern. Vor diesem Hintergrund wird in Abschnitt 2.6 das für die Entwicklung der FED-Methodik herangezogene Referenzsystem abgegrenzt, bevor abschließend mögliche Fehlerquellen innerhalb der Systemstruktur eingeordnet werden (Abschnitt 2.7).

### 2.1. Terminologie und Gliederung des FED-Prozesses

Die verwendete Terminologie im Bereich der FED ist in der Literatur nicht immer einheitlich definiert und kann abhängig vom Anwendungsgebiet variieren. Dennoch hat sich durch die zunehmend intensive Forschung und Anwendung von FED-Methoden in unterschiedlichsten Domänen eine Nomenklatur etabliert, die in Standard-Werken und Normen festgehalten wird. Hervorzuheben sind die Arbeiten von Isermann [11][12] und Ding [13][14], deren Begriffsdefinitionen in dieser Arbeit weitestgehend übernommen werden.

Isermann [12] definiert einen **Fehler** (engl.: fault) in einem technischen System wie folgt: „*Ein Fehler ist eine unerlaubte Abweichung von mindestens einer charakteristischen Eigenschaft (Feature) des observierten Systems von den akzeptablen, üblichen Standardbedingungen.*“<sup>1</sup>

---

<sup>1</sup> Frei übersetzt aus dem Englischen

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

---

Etwas spezifischer formuliert ist ein Fehler ein abnormaler Betriebszustand, der eine Reduktion oder den Verlust der Systemfunktion zur Folge hat. Hierzu zählen auch Kriterien hinsichtlich energetischer Performance und Komfort. Dabei kann zwischen vielen verschiedenen Fehlertypen unterschieden werden, wie Designfehler, Herstellungsfehler, Wartungsfehler, Hardwarefehler, Softwarefehler u.v.a.m. [12]. Je nach Fehlertyp und Zielstellung können sich die geeigneten FED-Ansätze grundlegend unterscheiden. In dieser Arbeit wird der Fehlerbegriff verwendet, um auf einen abnormalen Betriebszustand hinzuweisen, der im laufenden Betrieb, also nach Inbetriebnahme und Einregulierung, auftritt und entweder eine Reduktion der Energieeffizienz oder des Raumkomforts zur Folge hat. Systemische Designfehler oder Ausführungsfehler sind somit nicht inbegriffen. Der durch das FED-System observierte Fehler kann ein Indikator für eine **Betriebsstörung** (temporäre Beeinträchtigung, englisch: malfunction) oder ein **Betriebsausfall** (dauerhafter Verlust der Funktion, englisch: failure) sein.

Auch bei hohen Qualitätsstandards lassen sich in technischen Systemen Fehler im Betrieb nicht vollständig vermeiden. In Bereichen ohne sicherheitsrelevante Funktionen sollten FED-Methoden daher die Fähigkeit mitbringen, Fehler mit geringer Wirkung auf das Systemverhalten zu ignorieren. So kann die Anzahl der generierten Alarme reduziert und die Akzeptanz in der Anwendung erhöht werden. Der Begriff **Fehlertoleranz** bezieht sich in dieser Arbeit daher auf die Eigenschaft eines FED-Systems tolerant gegenüber Fehler mit geringer Wirkung auf das Betriebsverhalten zu sein. Das unterscheidet sich wesentlich von einer regelungstechnischen Betrachtung. Hier beschreibt die Fehlertoleranz die Fähigkeit eines Reglers, Fehler so zu kompensieren, dass die Systemfunktion nicht beeinträchtigt wird. Dies kann z.B. durch eine angepasste Betriebsweise oder den Einsatz eines redundanten Systems erfolgen.

Der ganzheitliche FED-Prozess kann in die Teilbereiche Fehlererkennung und Fehlerdiagnose gegliedert werden (siehe Abbildung 1). In der **Fehlererkennung (FE)** werden Anomalien (Symptome) in den Betriebsdaten aufgrund der Fehlereinflüsse identifiziert und ein binäres Signal hinsichtlich des allgemeinen Fehlerzustandes des Systems zeitlich getriggert. In der weiterführenden **Diagnose (FED)** werden die Fehlersymptome analysiert und zusätzliche Informationen über den Fehler extrahiert. Hierzu zählen die Teilschritte **Fehlerisolation (FI)**, hier werden Informationen über den Fehlertyp, den Ort und den Zeitraum des Fehlers extrahiert, und die **Fehleridentifikation**, in der die Charakteristiken, wie die Fehlergröße oder das zeitvariante Verhalten, bestimmt werden [12]. Ergänzend können die Auswirkungen der Fehler auf Performance-Indikatoren (englisch. Key Performace Indicator, KPI) des Systems, wie Kos-



## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

ten, Energieverbrauch und Komfortparameter evaluiert werden. Dieser Vorgang wird allgemein als **Fehlerevaluierung (FED&E)** bezeichnet [15]. Dabei lassen sich aus den gewonnenen Informationen Prioritäten und Handlungsempfehlungen ableiten. In jedem Teilschritt der Fehlererkennung, Diagnose und Evaluierung (FED&E) werden die extrahierten Informationen an den Nutzer übermittelt. Der FED-Prozess ist somit ein bedeutendes Werkzeug für die effiziente Durchführung eines technische Gebäudemonitorings im FM.

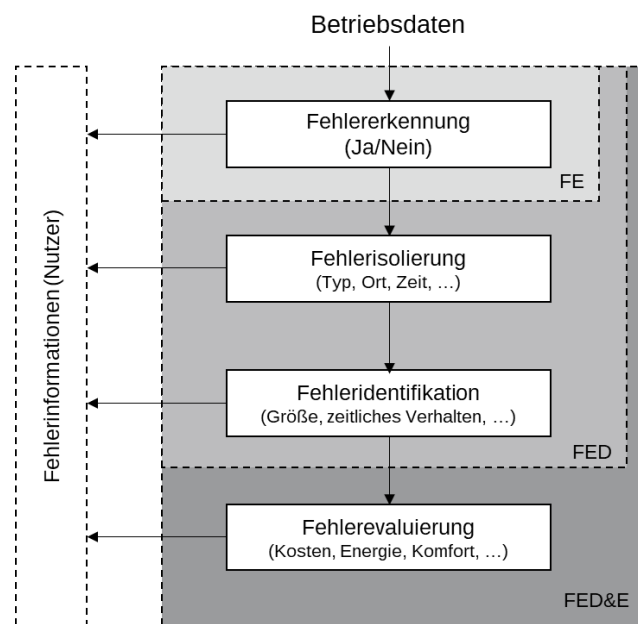


Abbildung 1: Teilschritte n der Fehlererkennung (FE), -diagnose (FED) und Evaluierung (FED&E) (In Anlehnung an [16] und [15]).

### 2.2. Klassifizierung von automatisierten Methoden

Eine FED im Betrieb von technischen Anlagen kann entweder durch den Aufbau redundanter Hardware oder analytische Redundanz erfolgen. Dabei können Softwarelösungen abhängig von ihrem methodischen Ansatz in verschiedene Kategorien gegliedert werden (siehe Abbildung 2, in Anlehnung an [17]).

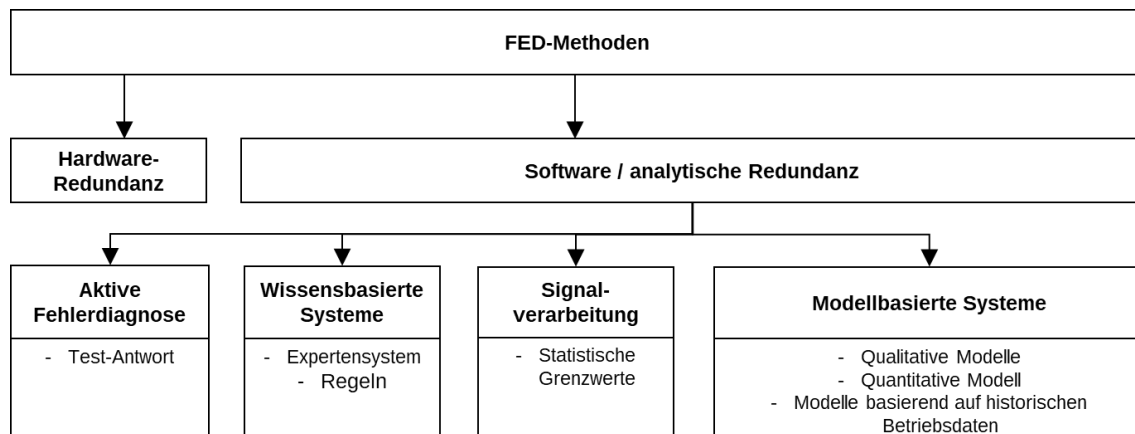


Abbildung 2: Kategorisierung unterschiedlicher FED-Methoden (in Anlehnung an [18]).

#### (i) Aktive Fehlerdiagnose

Unter einer aktiven Fehlerdiagnose versteht man Verfahren, die aktiv in den Prozess eingreifen und das Betriebsverhalten in zuvor definierten Test-Szenarien überprüfen (z.B. Sprungantwort). Derartige Methoden setzen allerdings voraus, dass der kontinuierliche Betrieb des Prozesses unterbrochen werden kann.

#### (ii) Wissensbasierte Systeme

Wissensbasierte Systeme, auch Expertensysteme genannt, beruhen auf kausalen Abhängigkeiten, welche mit verfügbarem Expertenwissen über den observierten Prozess erstellt werden. Im Kern basiert dieses System auf einer Sammlung von Informationen über das System, eine Datenbank, Abhängigkeiten (Regeln) und einer Komponente, die eine Beschreibung des gefundenen Fehlers beinhaltet. Aufgrund der einfachen Erstellung, effektiven Anwendung und verständlichen Interpretation der Ergebnisse sind wissensbasierte Systeme in der Praxis weit verbreitet. Sie setzen allerdings ein großes Maß an a priori Wissen über mögliche Fehlerzustände voraus.

#### (iii) Signalverarbeitung

Im signalverarbeitenden Ansatz wird vorausgesetzt, dass die Signale eines Prozesses Informationen über einen zu detektierenden Fehler in Form von Symptomen tragen. Eine FED kann in diesem Fall durch eine geeignete Signalverarbeitung durchgeführt werden. Typischerweise werden Funktionen im Zeitbereich, wie Betrag, arithmetische

oder quadratische Mittelwerte, Grenzwerte, Trends und statistische Kenngrößen (Momente), oder Funktionen im Frequenzbereich wie spektrale Leistungsdichte, Frequenzspektrallinien, Cepstrum-Analyse, etc. angewendet. Signalbasierte Methoden sind hauptsächlich für Prozesse mit stationären Betriebszugständen geeignet und somit für dynamische Prozess nur begrenzt anwendbar [18].

### (iv) Modellbasierte Systeme:

Häufig werden mathematische Modelle zur Beschreibung der Fehler-Symptom-Beziehungen eingesetzt. Diese Methoden werden als "modellbasierte Fehlererkennung und -diagnose" bezeichnet. Die Definition der Modelle wird dann zu einem bedeutenden Teil der Anwendungsentwicklung. Typische Modellansätze sind in Abbildung 3 klassifiziert.

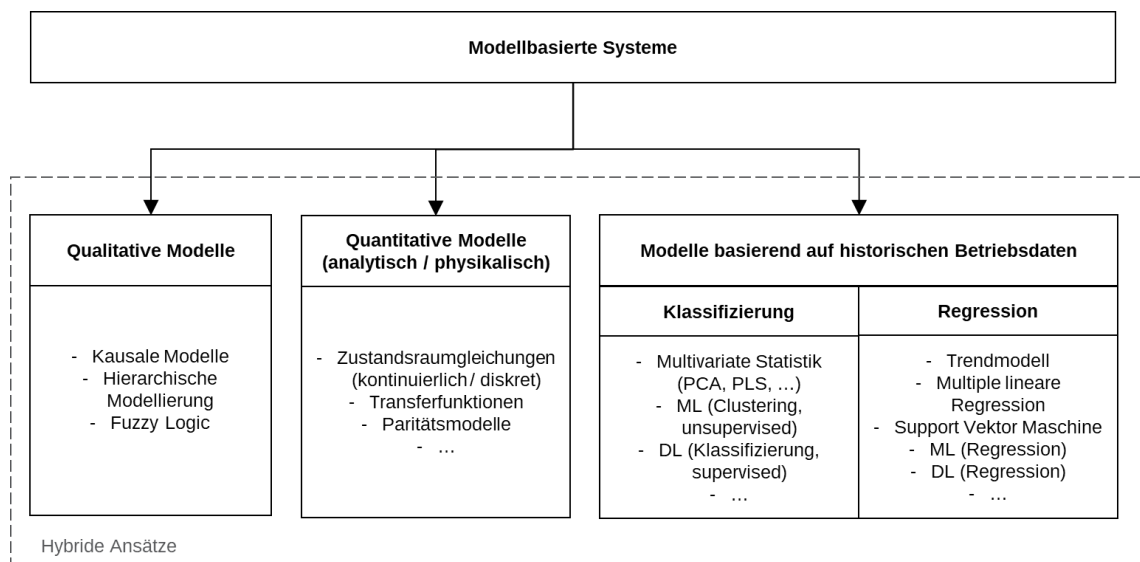


Abbildung 3: Klassifizierung modellbasierter FED-Ansätze.

Hierbei sind **quantitative Modelle** numerische Modelle wie algebraische Gleichungen und Differential- oder Differenzgleichungen. Beispielsweise können die Messwerte des realen Systems mit den Simulationsergebnissen eines detaillierten physikalischen Modells verglichen und die Abweichungen – meist durch die Berechnung von Residuen – bewertet werden.

**Qualitative Modelle** enthalten hingegen keine oder nur wenig Informationen über das Ausmaß von Fehlern oder deren Auswirkungen. Stattdessen verwenden sie Begriffe wie "hohe Temperatur", wobei oft Variablen verwendet werden, die binär oder nur wenig diskretisiert sind.

Im Gegensatz zu quantitativen und qualitativen Modellen, bei denen a priori Kenntnisse über den Prozess vorausgesetzt werden, wird bei selbstlernenden Ansätzen ange-

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

---

nommen, dass **historische Betriebsdaten** aus dem System vorhanden sind. Bei diesen sogenannten Black-Box-Modellen werden die Modellparameter (Input-Output-Beziehungen) ausschließlich anhand der verfügbaren Daten bestimmt. Es existiert eine Vielzahl unterschiedlicher mathematischer Ansätze, die sich für die Anwendung in der FED in Klassifizierungsmethoden, bei denen der Fehlerzustand oder Fehlertyp unmittelbar durch das Modell bestimmt wird, und Regressionsmethoden, die das Prozessverhalten im Geltungsbereich der vorhanden Betriebsdaten abbilden, unterscheiden lassen.

Mit dem Ziel die Modellgenauigkeit zu verbessern und die Zuverlässigkeit der Fehlerzuordnung zu erhöhen, werden häufig auch unterschiedliche Methoden zu **hybriden Ansätzen** kombiniert. Beispielsweise verknüpfen sogenannte Grey-Box-Modelle grundlegende physikalische Zusammenhänge mit datengetriebenen Methoden zur Schätzung der Modellparameter. Grundsätzlich wird bei hybriden Ansätzen versucht die Nachteile einer Methode durch den Einsatz einer zweiten Methode zu kompensieren, um so die Qualität des ganzheitlichen FED-Prozesses zu erhöhen.

*Tabelle 1: Klassifizierung von FED-Systemen hinsichtlich ihrer architektonischen Struktur sowie deren Vor- und Nachteile in der Anwendung [15].*

Beschreibung	Vorteile	Nachteile
<b>Nur Fehlererkennung</b>		
Detektion von Anomalien in den observierten Betriebsdaten	Unbekannte Fehler werden erkannt, flexibel einzusetzen	Keine Informationen über die Fehlerquelle und -typ
<b>Einstufige FED</b>		
Die in den Betriebsdaten observierten Fehlersymptome werden direkt einem Fehlertyp zugeordnet (z.B. Regeln)	Es kommt nur ein Algorithmus zum Einsatz	Unbekannte Fehler werden nicht erkannt.
<b>Zweistufige FED</b>		
Fehlererkennung und -diagnose werden mit zwei unterschiedlichen Algorithmen durchgeführt	Unbekannte Fehler werden erkannt, Fehlerisolation und -identifikation möglich	Komplex

Weiterhin lassen sich FED-Systeme hinsichtlich ihrer grundlegenden Architektur einteilen. Tabelle 1 gibt einen Überblick über die verschiedenen Ansätze, sowie deren Vor- und Nachteile. Systeme, die ausschließlich eine Anomalie-Erkennung durchführen, liefern keine Informationen über die Fehlerursache, während Ansätze, welche eine Form von Fehlermodellen beinhalten, auch eine weitere Diagnose ermöglichen. Hierbei kann zwischen einem einstufigen und einem zweistufigen FED unterschieden wer-

den. In einem einstufigen FED-Ansatz werden die Erkennung und die Diagnose mit einem einzigen Algorithmus durchgeführt. In einem zweistufigen Prozess kommen hingegen unterschiedliche Algorithmen zum Einsatz [15].

### 2.3. Residuen-generierender FED-Prozess

Ein etablierter Ansatz im Bereich der modellbasierten Methoden ist der Residuen-generierende FED-Prozess [13]. In diesem Ansatz wird das fehlerfreie Prozessverhalten durch ein redundantes Systemmodell abgebildet. Die Berechnungsergebnisse werden dann mit den gemessenen Regelgrößen  $y(t)$  abgeglichen (vgl. Abbildung 4, Residuen-Generator). Häufig werden in diesem Prozessschritt analytische, quantitative Modelle basierend auf der Zustandsraumdarstellung des Systems (sogenannte Beobachter) eingesetzt, weshalb sich dieser Ansatz sehr gut für dynamische Prozesse eignet. Nachteilig ist jedoch, dass die Erstellung prozessspezifisch und aufwendig ist.




Abbildung 4: Residuen-generierender FED-Prozess (in Anlehnung an [13]).

Die Kernaufgabe im Design des Residuen-Generators besteht darin, das Verhalten der resultierenden Residuen möglichst sensibel gegenüber Fehlern und gleichzeitig robust gegenüber Modellunsicherheiten, unbekannte Eingangsgrößen sowie Störungen  $d(t)$  zu gestalten. Die Grundvoraussetzung hierfür ist eine hohe Qualität des formulierten

Prozessmodells zur Berechnung der Residuen. Diese werden anschließend mit geeigneten Filtertechniken weiterverarbeitet, um deren Verhalten für bestimmte Fehlertypen zu sensibilisieren (oder unsensibel zu machen) und damit charakteristische Fehlermuster zu erzeugen [13].

In einem zweiten Schritt wird der resultierende Residuen-Vektor evaluiert und eine Entscheidung im Sinne einer Fehlerzuordnung getroffen. Die Toleranz des Gesamtprozesses gegenüber Fehlalarmen und die Qualität der FE hängt maßgeblich von der Evaluierungsmethode ab. Grundsätzlich kann zwischen statistischen und schwellenwertbasierten Methoden unterschieden werden [19]. Statistische Verfahren prüfen, ob sich die Parameter der Residualverteilung aufgrund von Fehlereinflüssen ändern (z. B. Likelihood-Ratio-Test). Dies erfordert jedoch eine ausreichend große Datenmenge innerhalb des ausgewerteten Intervalls (hoch aufgelöstes Logintervall), die bei HLK-Anlagen in der Regel nicht verfügbar ist. Bei schwellenwertbasierten Methoden wird typischerweise das Residuum mit einem konstanten oder adaptiven Schwellenwert verglichen [20]. Dieser Vorgang lässt sich der Fehlererkennung zuordnen. Da nicht unmittelbar das fehlerhafte Verhalten modelliert wird, erlaubt dieser Ansatz auch die Erkennung von unbekanntem Fehlern.

Die generierten Residuen tragen nicht nur Informationen über den Gesundheitszustand des Systems, sondern eröffnen auch eine Fehlerdiagnose. Unterschiedliche Fehlertypen zeigen Ihre Symptome in unterschiedlichen Positionen des Residuen-Vektors, wodurch das resultierende Muster Hinweise hinsichtlich des Fehlertyps und der Fehlerposition liefert. Zudem ist der Residuen-Betrag ein Indikator für die Fehlergröße. Durch die Modellierung des nominalen Verhaltens wird auch die Grundlage für eine Fehlerevaluierung gelegt und erfüllt damit wesentliche Kriterien zur Erfüllung der Zielstellung dieser Arbeit, das technische Monitoring von HKL-Anlagen im Bereich des FM zu unterstützen (vgl. Abschnitt 1.1).

### **2.4. Künstliche Intelligenz (KI) für die FED**

Der Einsatz von KI-Methoden<sup>2</sup> im Bereich der FED nimmt wie in anderen Domänen stetig zu. Insbesondere der Teilbereich des maschinellen Lernens (ML) hat aufgrund der zunehmenden Verfügbarkeit von Entwicklungswerkzeugen, der signifikant gestiegenen Leistungsfähigkeit der Modelle und der heute größeren Verfügbarkeit von Re-

---

<sup>2</sup> Künstliche Intelligenz beschreibt Informatik-Anwendungen, die zum Ziel haben intelligentes, menschenähnliches Verhalten nachzuahmen [61]. Technologisch lassen sich KI-Anwendung in heuristische, wissensbasierte, lernende und kognitive Systeme gliedern.

chenleistung sowie Daten an Bedeutung gewonnen. Durch ihre Flexibilität anhand von historischen Betriebsdaten Verhaltensmuster von technischen Systemen zu erlernen, haben sie großes Potenzial für die Realisierung von komplexen Anwendungen wie die FED [18][21]. Durch geeignete Optimierungsverfahren werden die Modellparameter anhand der verfügbaren Daten so angepasst, dass eine möglichst gute Schätzung für ungesehene Daten erzielt wird. Dieser Vorgang wird als Modelltraining bezeichnet. Hierbei ist die Qualität der Schätzung jedoch maßgeblich abhängig von den individuellen, systemspezifischen Datensätzen. Dies erfordert ein maßgeschneidertes Design hinsichtlich Datenverarbeitung, Modelltyp sowie -struktur und erhöht den Bedarf an Fachpersonal mit Kenntnissen im Bereich des ML, Entwicklungszeit sowie -kosten. Insbesondere im Bereich der technischen Gebäudeausrüstung stellt die begrenzte Übertragbarkeit von ML-Anwendungen eine besondere Herausforderung dar.

ML-Methoden lassen sich in drei Bereiche gliedern [22]:

- Supervised Learning (überwachtes oder beaufsichtigtes Lernen)
- Unsupervised Learning (unüberwachtes oder selbstorganisiertes Lernen)
- Reinforcement Learning (verstärkendes oder belohnungsbasiertes Lernen)

Wenn die verfügbaren historische Daten sowohl die Eingangs-, als auch die zugehörigen Ausgangsdaten (sogenannte Labels) umfassen, kommen i.d.R. Methoden aus dem Bereich des Supervised Learnings zum Einsatz. Sie erlernen die Input-Output Beziehungen anhand der für das Training genutzten Datensätze. Dabei kann hinsichtlich der Zielstellung und der Eigenschaft der zu schätzenden Zielvariabel(n) zwischen Regressions- und Klassifizierungsaufgaben unterschieden werden. Werden kontinuierliche Größen geschätzt (z.B. eine Temperatur), spricht man von einer Regression. Bei einer Zuweisung eines Datensatzes zu Kategorien oder diskreten Größen (z.B. ein Betriebsstatus Ein/Aus) von einer Klassifizierung. Oft können für beide Aufgaben die gleichen Supervised ML-Methoden eingesetzt werden. Der wesentliche Unterschied liegt dann in der Kodierung der Ausgangsgröße (sogenannte Encoder). Während bei einer Regression direkt der Zahlenwert geschätzt wird, liefert eine Klassifizierung die Zugehörigkeitswahrscheinlichkeit zu einer Kategorie. Sind nur wenige Labels für das Modelltraining vorhanden, werden in manchen Ansätzen auch künstliche Labels erzeugt. Hierbei spricht man dann von Semi-Supervised-Learning-Methoden.

Im Unsupervised Learning sind die Labels, z.B. der Fehlerzustand des Systems, hingegen nicht bekannt. Ein klassisches Beispiel ist das Clustering. Allgemein gesprochen werden hierbei verborgene Muster oder Strukturen in den Daten identifiziert und

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

---

ähnlichen Gruppen (Clusters) zugeordnet. Daten aus gebäudetechnischen Anlagen sind jedoch häufig durch eine hohe Varianz geprägt, wodurch die Identifizierung von eindeutigen Strukturen schwierig ist. Auch kann die Anzahl der Cluster für die Parametrisierung der Modelle vorab i.d.R. nicht eindeutig definiert werden. Ein spezieller Ansatz im Bereich des ML ist das Reinforcement Learning. Hier werden wie beim Un-supervised Learning Datensätze ohne Labels verwendet, jedoch interagiert das System mit der Umgebung, wodurch das Modellverhalten durch ein Feedback (z.B. durch den Nutzer) stetig verbessert wird (Belohnung oder Bestrafung).

Im Residuen-generierenden FED-Prozess auf Basis von ML-Methoden handelt es sich um eine Modellierungsaufgabe aus dem Bereich des Supervised Learnings [14]. In den historischen Betriebsdaten bilden die Verläufe der Schätzgrößen (Zielvariablen) die Labels für das Training eines Regressions- oder Klassifizierungsmodells. Tabelle 2 gibt einen Überblick über typische ML-Ansätze aus dem Bereich des Supervised Learnings. Häufig werden auch unterschiedliche Methoden miteinander kombiniert, um die jeweiligen Schwächen auszugleichen, oder bestehende Ansätze verändert (z.B. hinsichtlich der Verlustfunktion für das Modelltraining). Aufgrund der dynamischen Entwicklung im ML-Bereich liefert die Tabelle einen Überblick über aktuell häufig genutzte Methoden. Grundsätzlich können alle ML-Methoden in eine datengetriebene FED integriert werden, sofern sie in der Lage sind das dynamische Verhalten des observierten Systems wiederzugeben.

*Tabelle 2: Übersicht typischer ML-Methoden aus dem Bereich des Supervised Learnings. Extrahiert aus [23], [24]. Aufgrund ihrer weiten Verbreitung im deutschsprachigen Raum sind die englischen Bezeichnungen der Methoden aufgeführt.*

<b>ML-Methode</b>	<b>Aufgabe</b>	<b>Beschreibung</b>
(Multiple) Linear Regression (MLR)	Regression	Modelliert die Beziehung zwischen einer abhängigen Variablen und einer oder mehreren unabhängigen Variablen als lineare Gleichung.
Logistic Regression (RL)	Klassifizierung	Schätzt die Wahrscheinlichkeit eines binären Ergebnisses.
Bayesian Linear Regression / Bayesian Ridge	Regression	Bindet die Bayes'sche Analyse-Methode in die LR ein und liefert so probabilistische Interpretationen der Modellparameter.
Ridge Regression / Lasso Regression / Elastic Net	Regression	Erweitert die LR um einen Regularisierungs-Term in der Verlustfunktion, um ein Overfitting zu verhindern.



## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

ML-Methode	Aufgabe	Beschreibung
Passive-Aggressive Regressor	Regression	Ein Lernalgorithmus, der die Modellparameter nur dann (aggressiv) aktualisiert, wenn die Vorhersagefehler einen bestimmten Schwellenwert überschreiten.
Decision Trees (DT)	Regression / Klassifizierung	Sagt den Wert einer Zielvariablen durch Lernen von Entscheidungsregeln voraus, die aus den Daten abgeleitet werden.
Random Forest (RF)	Regression / Klassifizierung	Verwendet mehrere DT, um die Vorhersagegenauigkeit zu verbessern und ein Overfitting zu vermeiden.
Gradient Boosting Maschines	Regression / Klassifizierung	Besteht aus einem System von Decision Trees in einer sequenziellen Anordnung, wobei jeder Baum die Fehler der vorhergehenden korrigiert, und eine Verlustfunktion minimiert.
Support Vector Machines (SVM)	Regression / (meist) Klassifizierung	Findet die Hyperebene, die verschiedene Klassen im Merkmalsraum am besten trennt.
K-Nearest Neighbors (KNN)	Regression / Klassifizierung	Klassenzuordnung unter Berücksichtigung seiner $k$ nächsten Nachbarn im Merkmalsraum.
Naive Bayes (NB)	Klassifizierung	Wendet das Bayes-Theorem mit der Annahme an, dass die Eingangsdaten unabhängig voneinander sind.
AdaBoost	Regression / Klassifizierung	Boosting-Technik, die mehrere einfache klassifizierende Modelle kombiniert, um die Zuordnung von schwer zu klassifizierenden Daten zu verbessern.
Artificial Neural Networks (ANN)	Regression / Klassifizierung	ANNs schätzen die Zielgröße, indem die Informationen in einem Netz aus Neuronen mit individuellen Übertragungsfunktionen weitergeben und verarbeitet werden.
Multy-Layer-Perceptron (MLP) / Feedforward NN (FNN)	Regression / Klassifizierung	Der einfachste Typ eines neuronalen Netzes. Jede Schicht leitet die Informationen ohne Rückkopplung zur nächsten Schicht weiter.
Convolutional NN (CNN)	Regression / (meist) Klassifizierung	Spezialisiert auf die Verarbeitung von Daten mit gitterartiger Topologie, wie z. B. Bilder, unter Verwendung von Faltungsschichten zum automatischen und adaptiven Lernen räumlicher Hierarchien.

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

---

ML-Methode	Aufgabe	Beschreibung
Recurrent NN (RNN)	Regression / Klassifizierung	Entwickelt, um sequenzielle Datenmuster zu erkennen; enthält Rückkopplungen im Netzwerk, die es ermöglichen, Informationen über einen Verarbeitungsschritte hinaus zu erhalten.
Long Short-Term Memory NN (LSTM)	Regression / Klassifizierung	Ein RNN-Typ, der langfristige Abhängigkeiten erlernen kann.

### 2.4.1. Multilayer Perceptron (MLP)

Die Modellfamilie der künstlichen neuronalen Netze (ANN) wird häufig dem Teilbereich des Deeplearnings (DL) zugeordnet. Hierunter versteht man Modellarchitekturen, die neben einer Eingangsschicht (Input-Layer) und einer Ausgangsschicht (Output-Layer) eine variable Anzahl versteckter Schichten (Hidden-Layer) besitzen und somit komplexe Zusammenhänge in großen Datenmengen (Big-Data) erlernen können. Die Grenze zwischen traditionellen ML-Methoden und Deep-Learning sind nicht eindeutig definiert. In [22] wird von Deep-Learning gesprochen, wenn die erforderliche Rechenleistung die Nutzung von Rechencluster (HPC-Cluster, engl. high performance computing) erfordern<sup>3</sup>. Der Einsatz von komplexeren Modellen führt allerdings nicht kausal zu einer besseren Schätzqualität, sodass die geeignete Methode und die Architektur individuell für den gegebenen Datensatz gefunden werden müssen.

Die einfachste Form von neuronalen Netzen sind sogenannte Multilayer-Perceptron (MLP) neuronale Netze, oft auch als Feedforward ANNs bezeichnet. Eine typische MLP-Architektur für ein System mit  $n$  Inputs und einer einzelnen Schätzgröße zeigt Abbildung 5. Die Anzahl der Neuronen in den Hidden-Layers kann einen beliebigen Wert annehmen, da sie von der Eingangs- oder Ausgangs-Dimensionalität unabhängig ist. Das gerichtete Weitergeben der Informationen vom Input hin zum Output wird als Vorwärtspropagation bezeichnet. Dabei berechnet ein einzelnes Neuron seinen Output auf Basis der gewichteten Ergebnisse aller Neuronen aus dem vorherigen Layer sowie einer Aktivierungsfunktion (Transferfunktion). Übliche Aktivierungsfunktionen sind: Rectified Linear Unit (ReLU), Tangens hyperbolicus (Tanh), Sigmoid oder Softmax<sup>4</sup> (siehe Abbildung 6). Diese verleihen dem neuronalen Netz eine nichtlineare Eigen-

---

<sup>3</sup> Hinweis: In dieser Arbeit werden Modellarchitekturen mit einer geringen Layer- und Neuronen-Anzahl angewendet, deren Training keine spezielle IT-Infrastruktur, wie Hochleistungsrechner, notwendig macht.

<sup>4</sup> Die Softmax-Funktion wird im Output-Layer klassifizierender Modelle verwendet, um die Wahrscheinlichkeit einer Klasse für den gegebenen Datensatz zu bestimmen

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

schaft. Allgemein ergibt sich für das Ergebnis eines Neurons  $j$  in der Schicht  $l$  folgende Gleichung [25]:

$$z_j^{(l)} = \sigma \left( \sum_{i=1}^{n_{l-1}} w_{j,i}^{(l)} * x_i^{l-1} + b_j^l \right) = \sigma(\vec{w}_j^T * \vec{x}^{(l-1)} + b_j^l) \quad (1)$$

$$y_j^{(l)} = \sigma(z_j^{(l)}) \quad (2)$$

- $y_j^{(l)}$ : Ergebnis des Neurons  $j$  im Hidden – Layer  $l$   
 $z_j^{(l)}$ : Gewichtete Summe des Neurons  $j$  im Hidden – Layer  $l$   
 $\sigma$ : Aktivierungsfunktion  
 $w_{j,i}^{(l)}$ : Gewicht der Verbindung vom Neuron  $i$  in der Schicht  $l - 1$  zum Neuron  $j$  in der Schicht  $l$   
 $x_i^{l-1}$ : Ausgabe des Neurons  $i$  in der Schicht  $l - 1$   
 $b_j^l$ : Bias des Neurons  $j$  in der Schicht  $l$   
 $\vec{w}_j^T$ : Gewichtsvektor des Neurons  $j$  im Hidden – Layer  $l$   
 $\vec{x}^{(l-1)}$ : Ergebnisvektor des Hidden – Layer  $l - 1$




Abbildung 5: Struktur eines MLP-Netzwerkes mit  $n$  Inputs und einem Output.  
Eigene Darstellung in Anlehnung an [23].

Im Trainingsprozess wird die Schätzung zunächst mit Startwerten für die Gewichtungsfaktoren berechnet. Auf Basis der Abweichung werden anschließend die Gewichtungsfaktoren rückwärtsgerichtet (vom Ausgangs- zum Eingangs-Layer) angepasst. Auf diese Weise wird iterativ die Abweichung verringert. Diese Technik wird in der Literatur als Backpropagation bezeichnet [26]. Dabei kann zwischen zwei grundsätzlichen Ansätzen unterschieden werden. Bei einem stochastischen Ansatz werden einzelne, zufällig gezogene Proben aus dem Datensatz für das Training verwendet und die Gewichtungsfaktoren i.d.R. über ein Gradientenverfahren aktualisiert. In der Batch-Methode wird hingegen der gesamte Datensatz in sogenannte Batches (Teilmenge) aufgeteilt

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

und an das Netzwerk gesendet, bevor der Fehler berechnet und die Gewichte aktualisiert werden. Wurden alle Teilmengen einmal für ein Update der Modellparameter verwendet, spricht man von einer Epoche. In der Regel werden eine Vielzahl Epochen benötigt, bevor der Algorithmus vollständig konvergiert. Da beim Batch-Lernen in jeder Iteration eine Ansammlung von Stichproben verwendet wird, ist der Lernprozess im Vergleich zum stochastischen Verfahren mit weniger Rauschen behaftet. Die Schrittweite für die Anpassung der Parameter während des Trainings wird durch die Lernrate (engl. learning rate) definiert [27].




Abbildung 6: Unterschiedliche Aktivierungsfunktionen von neuronalen Netzen. Das dargestellte Beispiel für die Softmax-Funktion zeigt das Resultat für drei möglichen Klassen.

Für das Erlernen von Mustern in sequenziellen Daten kommen häufig komplexere, sogenannte rekurrente neuronale Netze (engl.: Recurrent NN, RNN) zum Einsatz. Durch eine Rückkopplung innerhalb der Netzstruktur werden Ergebnisse aus vorherigen Eingaben verwendet, um die aktuelle Berechnung zu beeinflussen. Damit wird dem Netzwerk eine Speicherfunktion (Gedächtnis) verliehen, wodurch dynamische Effekte, wie sie auch in gebäudetechnischen Anlagen auftreten, erlernt werden können. Insbesondere eine Weiterentwicklung, sogenannte Long Short-Term Memory (LSTM) RNNs, ermöglichen auch das Erlernen von langzeitigen Trends und haben sich daher im Bereich der Zeitreihen-Modellierung durchgesetzt [22]. Voruntersuchungen im Rahmen dieser Arbeit haben jedoch gezeigt (Abschnitt 6.1.1), dass MLPs bereits mit wenigen Hidden-Layers ( $m \leq 7$ ) und Neuronen-Anzahl je Hidden-Layer ( $i \leq 552$ ) durch die Verwendung eines gleitenden Zeitfensters der Eingangsdaten in der Lage sind das dynamische Verhalten von Lüftungsanlagen gut zu erfassen und damit prinzipiell für die Anwendung in einem Residuen-generierenden FED-Prozess geeignet sind. LSTM-Netzwerke erreichen vergleichbare Ergebnisse, benötigen jedoch aufgrund des deutlich komplexeren Modelltrainings eine höhere Rechenleistung.

### 2.4.2. Generalisierung und Overfitting

Während des Modelltrainings werden die Verluste nach einer vordefinierten Verlustfunktion minimiert. Typische Verlustfunktionen (Metriken) für Regressionsanwendungen sind die mittlere quadratische Abweichung (MSE), die Wurzel der mittleren quadratischen Abweichung (RMSE) oder die mittlere absolute Abweichung (MAE). In Klassifizierungsanwendungen kommt meist die Kreuzentropie zum Einsatz (siehe Anhang A1). Findet das Optimierungsverfahren keine gegen Null konvergierende Lösung ist entweder der gewählte Modelltyp ungeeignet oder es liegt ein lokales Minimum vor, sodass das Training mit neuen Startwerten durchgeführt werden muss. Voraussetzung ist die Existenz von statistischen Zusammenhängen zwischen Eingangsdaten und Schätzwert.

Aber auch wenn die Trainingsverluste mit zunehmender Anzahl von Iterationen sinken, bedeutet dies nicht kausal, dass das Modell für die Anwendung geeignet ist. Das Ziel im ML ist es, statistische Muster in einem Trainingsatz zu finden, die sich außerhalb des Trainingsatzes verallgemeinern lassen. Hierbei spricht man von der Fähigkeit des Modells zu generalisieren. Aus diesem Grund werden vorab ein Teil der historischen Daten zurückbehalten und während des Modelltrainings die Verluste auf diesen Validierungsdatensatz observiert. Typischerweise liegen die Validierungsverluste oberhalb der Trainingsverluste. Mit steigender Anzahl Iterationen ist es wahrscheinlich, dass die Validierungsverluste nicht weiter sinken oder möglicherweise wieder anfangen zu steigen, obwohl die Trainingsverluste weiterhin abnehmen. In diesem Fall erlernt das Modell Muster anhand der Trainingsdaten, die sich nicht mehr generalisieren lassen. Hierbei spricht man von einer Überanpassung (engl. Overfitting). Insbesondere für Modelle mit einer großen Anzahl von Parametern, wie neuronale Netze, ist ein Overfitting typisch. Im Gegensatz dazu, spricht man von einer Unteranpassung (engl. Underfitting), wenn das Modell nicht ausreichend trainiert wird. Eine effiziente Methode zur Vermeidung von Overfitting ist, das Training bei stagnierenden oder steigenden Validierungsverlusten abubrechen (engl. early-stopping). Allgemein spricht man bei Methoden, die eine Überanpassung verhindern und die Generalisierung erhöhen, von einer Regularisierung<sup>5</sup>. Im Bereich der Neuronalen Netze ist ein wichtiger Ansatz das sogenannte Dropout. Hierbei werden in jedem Iterationsschritt des Trainings zufällig

---

<sup>5</sup> Grundsätzlich generalisieren Modelle mit kleinen Gewichtungsfaktoren besser. Eine weitere Regularisierungsansatz ist daher, hohe Faktoren während des Trainings zu bestrafen. Typischerweise werden die L1- (LASSO) oder die L2- (Ridge Regression) Regularisierung angewendet.

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

einzelne Neuronen ausgelassen. Die Dropout-Rate definiert dann die Menge der ausgelassenen Neuronen [27].




Abbildung 7: Exemplarische Verläufe für die Trainings- und Validierungsverluste in Abhängigkeit von der Anzahl Iterationen.

Zusätzlich darf der in den Trainingsdaten enthaltene systematische Fehler nicht vernachlässigt werden, wie bspw. das Fehlen von (normalen) Betriebszuständen in den Trainingsdaten. Es ist daher unerlässlich die Modellperformance anhand ungesehener Daten zu testen (Testdatensatz). Ein entscheidender Arbeitsschritt im gesamten Modellierungsprozesses ist daher die Einteilung der historischen Zeitreihendaten in Trainings-, Validierungs- und Testzeiträume (Abbildung 8).




Abbildung 8: Gliederung der Betriebsdaten in Trainings-, Validierungs- und Testzeiträume.

Eine Gliederung der Daten in repräsentative Teilmengen erfordert eine ausreichende Datenverfügbarkeit. Wenn der Datensatz zu klein ist, können beispielsweise Kreuzvalidierungstechniken zur Auswahl von Modellhyperparametern verwendet werden. In der K-Fold-Kreuzvalidierung wird der Trainingsdatensatz in  $k$  Teilmengen aufgeteilt, wobei  $k-1$  Teilmengen zum Trainieren und die letzte Teilmenge zur Validierung eingesetzt wird. Dieser Prozess wird  $k$ -mal wiederholt, wobei jede  $k$ -te Teilmenge einmal zur Validierung verwendet wird. Für das Anpassen der Modellparameter wird dann die Modellperformance über alle Teilmengen gemittelt. Dieser statistische Ansatz verhindert ein Overfitting und ermöglicht eine robustere Evaluierung der Performance. Im Falle von Zeitreihen ist die Kreuzvalidierung nicht trivial. Eine zufällige Auswahl von Stichproben und Zuordnung zum Trainings- oder Validierungsdatensatz birgt die Gefahr, dass die bestehenden zeitlichen Abhängigkeiten aufgelöst und somit nicht richtig erlernt werden. Daher wird bei Zeitreihendaten i.d.R. ein rollender Ansatz angewendet,

bei dem die Anordnung der Datensätze nicht verändert wird. Ein genereller Nachteil von Kreuzvalidierungsverfahren ist der signifikant ( $k$ -mal) steigende Trainingsaufwand [28] [29] [30].

### 2.4.3. Bayes'sche Optimierung und Hyperparameter Tuning

Der Hauptunterschied zwischen einem Hyperparameter und einem Parameter (bspw. die Gewichtungsfaktoren für MLP) besteht darin, wie sein Wert bestimmt wird. Die Parameter eines ML-Modells werden im Trainingsprozess anhand der Daten ermittelt, während die Hyperparameter vom Entwickler vorgegeben werden. Typische Hyperparameter für MLP sind:

- Dropout-Rate, Anzahl der Epochen, Größe der Batches, Lernrate, Aktivierungsfunktion, Anzahl der Hidden-Layers und die Neuronenanzahl je Layer.

Die manuelle Suche nach geeigneten Hyperparameter für den gegebenen Datensatz ist aufgrund der Vielzahl möglicher Kombinationen im Hyperparameter-Raum ein aufwändiger heuristischer Prozess, der durch den Einsatz von automatisierten Optimierungsmethoden signifikant unterstützt werden kann. Nichtsdestotrotz steigt der Rechenaufwand bei einer großen Anzahl Hyperparameter und gleichzeitig feiner Diskretisierung für die Suche drastisch, da für jede Stichprobe aus dem Hyperparameter-Raum ein Modelltraining durchgeführt und evaluiert wird. Es sind jedoch nicht alle Hyperparameter gleichwertig signifikant, weshalb nur die wichtigsten Größen für das Tuning fokussiert werden sollten.

Optimierungsmethoden, die im Bereich des Hyperparameter Tuning von ML-Modellen eingesetzt werden, lassen sich in insgesamt fünf Kategorien einteilen. Tabelle 3 gibt einen Überblick der Methoden sowie deren Vor- und Nachteile [30].

Im Gegensatz zu systematischen und zufälligen Such-Algorithmien berücksichtigt die Bayes'sche Optimierung (BO) die Ergebnisse vorheriger Untersuchungen und benötigt daher weniger Stichproben. Auch im Vergleich zu evolutionären Algorithmen erzielt die BO mit weniger Trainings-Iterationen konvergierende Lösungen und eignet sich daher besonders für den in dieser Arbeit verfolgten FED-Ansatz mit einer individuellen Modellierung der Schätzgrößen. Gleichzeitig ist die BO ein etablierter Ansatz in Kombination mit neuronalen Netzen, der in vielen ML-Bibliotheken verfügbar und somit gut in eine ML-Pipeline zu integrieren ist.

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

Tabelle 3: Unterschiedliche Optimierungsmethoden für das Tunen von Hyperparametern im Bereich des maschinellen Lernens. Die Kategorisierung erfolgt in Anlehnung an [30].

Optimierungsmethode	Vorteile	Nachteile
<b>Systematische und zufällige Suche</b>		
Grid Search	Einfache Implementierung	Rechenintensiv bei großen Parameterräumen
Random Search	Effizient bei großen Parameterräumen	Keine Garantie für optimale Parameter
Hyperband	Ressourcenschonend durch frühes Abbrechen.	Komplexe Implementierung
<b>Probabilistische Modelle</b>		
Bayes'sche Optimierung	Effizienter bei der Suche nach optimalen Parametern durch die Nutzung von Informationen aus früheren Tests.	Komplex zu implementieren, benötigt ein gutes Modell für die Performance-Funktion
<b>Gradientenbasierte Methoden</b>		
Gradientenbasierte Optimierung	Effizient bei differenzierbaren Hyperparameter.	Nicht anwendbar bei diskreten Parametern
<b>Evolutionäre Methoden</b>		
Genetische Algorithmen	Gut geeignet für große oder komplexe Parameterräume. Gleichzeitig flexibel und kann gut globale Optima finden.	Kann rechenintensiv sein und benötigt viele Iterationen für eine konvergierende Lösung
<b>Lernbasierte Methoden</b>		
Reinforcement Learning	Kann sich an komplexe und ändernde Umgebungen anpassen.	Hohe Rechenkosten und komplex in der Implementierung
Transfer-Learning	Reduziert die Optimierungszeit	Eine Übertragbarkeit ist nicht immer gegeben

Die Bayes'sche Optimierung lässt sich in folgende Schritte gliedern [30]:

- *Initialisierung*: Der Optimierungsprozess wird mit zufällig gewählten Startwerten begonnen und ein Modelltraining zur Generierung initialer Daten durchgeführt.
- *Schätzung der Performance*: Ein Ersatzmodell (engl. surrogate model) wird genutzt, um die Performance unterschiedlicher Hyperparameter-Kombinationen zu schätzen. Typischerweise wird ein (stochastischer) Gauß-Prozess als Zielfunktion angewendet.



- *Auswahl einer neuen Stichprobe:* Der Optimierer nutzt eine Akquisitionsfunktion, um die nächste Stichprobe aus dem Hyperparameter-Raum auszuwählen. Dabei wird sowohl die geschätzte Performance durch das Ersatzmodell als auch die Unsicherheit berücksichtigt. Eine mögliche Aktivierungsfunktion ist die erwartete Verbesserung (EV) nach folgender Gleichung [30]:

$$EV(x) = (\mu(x) - f_{best}) * \Phi(Z) + \sigma(x) * \phi(Z) \quad (3)$$

mit  $Z = (\mu(x) - f_{best})/\sigma(x)$

- x:* Ein Punkt im Hyperparameter – Raum
  - $\mu(\vec{x})$ :* Erwarteter Mittelwert der Zielfunktion (Gauß – Prozess)
  - $f_{best}$ :* Der bis zur aktuellen Iteration Beste Wert der Zielfunktion
  - $\sigma(\vec{x})$ :* Vorhergesagte Standardabweichung der Zielfunktion
  - $\Phi$ :* Dichtefunktion der Normaverteilung
  - $\phi$ :* Verteilungsfunktion der Normalverteilung
- *Iteration:* Der Optimierer evaluiert die Ergebnisse der gefunden Hyperparameter und führt ein Update des Ersatzmodells durch. Anschließend wird der Prozess wiederholt, bis die maximale Anzahl Iterationen oder ein Konvergenzkriterium erfüllt ist.

### 2.5. Verwandte FED-Ansätze in der Literatur

Die zunehmende Notwendigkeit von automatisierten Methoden für eine kontinuierliche Betriebsüberwachung von gebäudetechnischen Anlagen zeigt sich auch in der Literatur. Zahlreiche FED-Ansätze werden in der Literatur präsentiert und dessen aktuelle Entwicklung über die Jahre in mehreren Review-Veröffentlichungen festgehalten. Tabelle 4 gibt hierzu einen Überblick von in der Vergangenheit viel zitierten und aktuelle Review-Veröffentlichungen. Hervorzuheben ist zudem die Arbeit der Internationalen Energieagentur (IEA) im Themenfeld „Energie in Gebäuden und Gemeinden (engl. Energy in Buildings and Communities, EBC)“ mit ausführlichen Projektberichten zum aktuellen Stand der Forschung und Praxisanwendungen. Beginnend mit dem Projekt IEA-EBC Annex 25 („Real-time simulation of HVAC systems for building optimization, fault detection, and diagnostics) im Jahr 1998 [31], wurde die Arbeit mit Annex 34 (Computer-aided Fault detection and Diagnosis, 2006) [32][33] und aktuell mit Annex 81 (Subtask C, Automated Fault Detection, Diagnostics, and Recommissioning Applications) stetig fortgeführt.

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

Tabelle 4: Auswahl bedeutender und aktueller Review-Veröffentlichungen zum Thema Fehlererkennung und Diagnose in gebäudetechnischen Anlagen. Aktualisiert auf Basis von [15].

Titel	Autor(en), Referenzen, Jahr	Beschreibung
Review article: Methods for Fault detection, Diagnosis, and Prognostics for Building Systems - A Review, Part I + II	S.Katipamula und M.R. Brambley, [5] [16], 2005	Eine der ersten umfassenden FED-Reviews mit Fokus auf gebäudetechnischen Anlagen. Klassifiziert FED-Methoden und beschreibt die Stärken sowie die Schwächen.
A review of fault detection and diagnostics methods for building systems	W. Kim und S. Katipamula, [6], 2018	Update von [5] und [16]
Artificial intelligence-based fault detection and diagnosis methods for building energy systems: Advantages, challenges and the future	Y. Zhao, T. Li, X.Zhang et al., [21], 2019	Review einer großen Menge FED-Veröffentlichungen sowie Einteilung in daten- und wissensgetriebene Ansätze. Diskussion und Empfehlung für zukünftigen Forschungsbedarf.
Fault detection and diagnosis of large-scale HVAC systems in buildings using data-driven methods: A comprehensive review	M. Mirnaghi, F. Haghghat, [17], 2020	In dieser Übersicht werden datengetriebene FED-Methoden aus der Literatur in drei Klassen eingeteilt: supervised, unsupervised und hybride Lernmethoden.
Knowledge Discovery by Analyzing the State of the Art of Data-Driven Fault Detection and Diagnostics of Building HVAC	A. H. Gourabpasi, M. Nik-Bakht, [34], 2021	Dieses Review Paper nutzt ML-Methoden, um anhand der Literatur Muster hinsichtlich des aktuellen Stands der Forschung zu erkennen und leitete daraus Empfehlungen für die Praxis ab.
Fault Detection and Diagnosis Encyclopedia for Building Systems: A Systematic Review	S. P. Melgaard, K. H. Andersen et al., [15], 2022	Systematische Auswertung von 221 Veröffentlichung und Auswertung hinsichtlich Glossars für den FED-Prozess, Klassifizierung der Ansätze, Datengrundlage und Performance-Metriken sowie zukünftiger Forschungsbedarf.
Machine Learning Methods for Automated Fault Detection and Diagnostics in Building Systems—A Review	W. Nelson C. Culp, [35], 2022	Übersicht verschiedener ML-Techniken und deren Anwendung im Bereich der FED in gebäudetechnischen Anlagen sowie Diskussion der Hemmnisse für die Anwendung.

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

---

<b>Titel</b>	<b>Autor(en), Referenzen, Jahr</b>	<b>Beschreibung</b>
A Review of Data-Driven Approaches and Techniques for Fault Detection and Diagnosis in HVAC Systems	I. Mateti, I. Štajduhar, [36], 2023	Fokussierung auf datengetriebene Ansätze. Die Autoren analysieren die Veröffentlichung hinsichtlich Best-Practice Empfehlungen für Entwickler und Forscher.
Review on Fault Detection and Diagnosis Feature Engineering in Building Heating, Ventilation, Air Conditioning and Refrigeration Systems	G. Li, Y. Hu et al., [37], 2023	Umfassende und einzige Review-Studie, die sich auf Methoden zur Feature-Auswahl für datengetriebene FED-Ansätze im Gebäudebereich konzentriert.

Hinsichtlich des Residuen-generierenden FED-Ansatz und dessen allgemeinen theoretischen Grundlagen sind insbesondere die Arbeiten von Ding [13][38][39][40][41] hervorzuheben, wobei Ding in [14][18] den Fokus auf datengetriebene Ansätze legt. Die Arbeiten zeigen, dass die Residuen-generierende FED domänenübergreifend einen etablierten Ansatz darstellt. Dennoch sind anwendungsorientierte Veröffentlichungen im Bereich der Gebäudetechnik selten.

Eine verwandte Arbeit zu residualen FED-Ansätzen mit ML-Methoden im Gebäudebereich findet sich in Wang et al. [42]. Die Autoren stellen eine robuste Strategie zur FED bei multiplen Fehlern in Lüftungssystemen vor. Während die Fehlererkennung auf einem statistischen Modell (exponentiell gewichteter gleitender Mittelwert, engl. EWMA) und den daraus resultierenden Residuen basiert, wird die Diagnose mithilfe von Expertenregeln durchgeführt. Einen ähnlichen Ansatz verfolgen Liao et al. [43]. Hier wird jedoch zunächst der Sensorstatus durch einen Regelsatz anhand der Residuen ermittelt und anschließend eine Fehlerisolation unter Anwendung eines faltendes neuronales Netz (engl. Convolutional Neural Network, CNN) durchgeführt. Lee et al. [44] verwenden verallgemeinerte Regressions-NN (engl. General Regression NN, GRNN) für die Residuen-Generierung in Kombination mit Regeln für die Fehlerdiagnose auf Ebene der Teilsysteme eines RLT-Gerätes. Bezyan et al. [45] nutzen Support-Vector-Machine-Modelle (SVM) zur Vorhersage der Temperaturen von zwei Sensoren in einem RLT-Gerät, während ein zweites rekurrentes neuronales Netz zur Vorhersage der Regressor-Eingänge unter normalen Bedingungen verwendet wird. Die Fehlerdiagnose erfolgt durch regelbasierte Techniken. Du et al. [46] konzentrieren sich auf Sensor- und Aktorfehler im Kühlbetrieb einer RLT-Anlage. Dabei kombinieren sie ein Basis-NN mit einem Hilfs-NN, um Anomalien zu erkennen und den Fehler durch eine subtraktive

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

---

Clusteranalyse im Datenraum zu klassifizieren. Ein verteiltes Konzept auf der Komponentenebene einer Lüftungsanlage (Kühlregister und VAV-Box) verfolgen Shahnazari et al. [47]. Dazu verwenden sie rekurrente neuronale Netze, um das fehlerfreie Verhalten vorherzusagen und anschließend Regeln für den Fehler zu isolieren. Die Autoren demonstrieren die Performance anhand von Betriebsdaten eines Kühlregisters.

Eine Übersicht der aufgeführten Veröffentlichungen, deren eingesetzten KI-Methoden und die verwendete Datengrundlage zur Performance-Bewertung zeigt Tabelle 5. Während für die Residuen-Generierung unterschiedliche ML-Methoden zum Einsatz kommen, erfolgt die Residuen-Evaluierung meist über Expertenregeln. Keine der in der Literatur veröffentlichten Studien führt eine systematische Bewertung der FED-Performance auf Datensätze unterschiedlicher Quellen durch. Dabei ist bekannt, dass die Performance von ML-Modellen stark vom individuellen Datensatz abhängig ist. Insbesondere der Einsatz von synthetischen Daten kann zu einer deutlich besseren Performance im Vergleich Einsatz mit realen Betriebsdaten führen. Zudem muss das FED-System in der Lage sein, sich automatisch an die Randbedingungen des jeweiligen Systems zu adaptieren (z.B. Anzahl der vorhandenen Datenpunkte, Logintervall, etc.), mit möglicherweise signifikanten Auswirkungen auf die Qualität der generierten Residuen. Insbesondere das Finden geeigneter Grenzwerte für die Residuen-Evaluierung wird damit zu einer wesentlichen Herausforderung in der praktischen Anwendung. Dies zeigt, dass die Übertragbarkeit in den veröffentlichten Studien unzureichend adressiert wird, obwohl dies in der Praxis ein wesentliches Hemmnis für die Anwendung von FED-Methoden im technischen Monitoring von Gebäuden darstellt.

*Tabelle 5: Ausgewählte Veröffentlichungen mit Residuen-Generierenden FED-Ansätzen für gebäudetechnischen Anlagen, die eingesetzten KI-Methoden und verwendete Datengrundlage*

Veröffentlichung	KI-Methode		Datengrundlage
	Residuen-Generierung	Residuen-Evaluierung	
[42]	Exponentiell gewichteter gleitender Mittelwert (EWMA)	Grenzwerte & Expertenregeln	Betriebsdaten einer realen RLT-Anlage
[43]	Gewichteter gleitender Mittelwert (WMA)	Regeln & Convolutional NN (CNN)	Betriebsdaten aus einer Laborkumgebung
[44]	General Regression NN (GRNN)	Expertenregeln	Synthetische Betriebsdaten

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

---

Veröffentlichung	Residuen-Generierung	KI-Methode	Residuen-Evaluierung	Datengrundlage
[45]	Support-Vector-Machine (SVM) & Recurrent NN (RNN)	Expertenregeln		Reale Betriebsdaten einer RLT-Anlage
[46]	Multi-Layer-Perceptron NN (MLP)	Cluster-Analyse		Synthetische Betriebsdaten (TRNSYS)
[47]	Recurrent NN (RNN)	Expertenregeln		Synthetische und reale Betriebsdaten einer RLT-Anlage

---

### 2.6. Abgrenzung des Referenzsystems (RLT-Anlage)

In Abhängigkeit der Gebäudenutzung und des umgesetzten Energiekonzeptes, unterscheiden sich technische Anlagen zur Gebäudeversorgung hinsichtlich Komplexität und Auswahl der technischen Lösungen. Dennoch lassen sich Teilsysteme, wie Lüftungsanlagen, Wärmeübergabestationen, Verteilkreise, etc., identifizieren, welche wiederkehrend in der Gesamtanlage auftreten. Vor diesem Hintergrund erfolgt die Entwicklung auf der Ebene eines ausgewählten Teilsystems (Referenzsystems). Die Schwierigkeit besteht darin, die FED-Methodik auf ein neues System mit einer zwar identischen Dienstleistung (z.B. Luftbehandlung), aber anderen Nominalwerten, Datengrundlagen, Funktionen und Regelstrategien anzuwenden. Die Parametrisierung des FED-Systems muss daher möglichst automatisiert auf Basis der historischen Betriebsdaten des zu observierenden Teilsystems stattfinden, um so den Aufwand für die Implementierung möglichst gering zu halten und eine gute Übertragbarkeit zu gewährleisten.

Abbildung 9 zeigt exemplarisch die Gliederung eines einfachen HKL-Systems in seine Teilkomponenten Wärmeerzeugung (WE), Wärmespeicherung (WSP), Verteilkreise (VK), Wärmeübertragung (WÜ), thermische Zone und raumluftechnische Anlage (RLT).

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

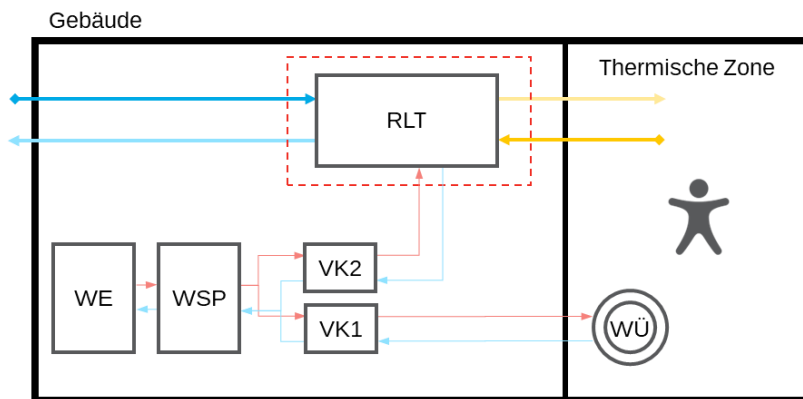


Abbildung 9: Beispielhafte Gliederung eines HLK-Systems in die Teilkomponenten Wärmeerzeugung (WE), Wärmespeicherung (WSP), Verteilkreise (VK), Wärmeübertragung (WÜ), thermische Zone und raumlufttechnische Anlage (RLT). Die rot gestrichelte Linie zeigt die Grenze für das gewählte Referenzsystem.

RLT-Anlagen lassen sich sowohl örtlich als auch regelungstechnisch eindeutig vom Gesamtsystem der technischen Gebäudeausrüstung abgrenzen und werden in dieser Arbeit als Referenzsystem für die Entwicklung einer ganzheitlichen FED-Methodik herangezogen. Die gewählte Systemgrenze (Abbildung 9, rot gestrichelte Linie) lässt sich durch folgende charakteristische Eigenschaften des Teilsystems begründen:

- Die Zustandsgrößen der Frischluft, der Zuluft, der Fortluft und der aus der versorgten Gebäudezone entnommenen Abluft werden i.d.R. messtechnisch erfasst und können als bekannte Ein- und Ausgangsgrößen des Teilsystems vorausgesetzt werden.
- Eine mathematische Beschreibung des (gesamten) dynamischen Gebäudeverhaltens ist sehr komplex und mit hohen Unsicherheiten behaftet. Durch die Messung der Abluftkonditionen werden wesentliche Einflüsse der thermischen Gebäudehülle und des Nutzerverhaltens messtechnisch erfasst. Hierdurch kann die Modellierungsaufgabe auf das observierte Teilsystem begrenzt werden.
- Einflüsse anderer (dynamischer) Rückkopplungen mit dem Gebäude können als gering eingestuft werden (z.B. geringe Veränderung der Umgebungstemperatur am Aufstellort).
- Lüftungsanlagen sind i.d.R. abgeschlossene Regelkreise. Eine Anbindung an die übergeordnete Gebäudeleittechnik erfolgt meist nur über Freigaben oder/und Vorgabe von Sollwerten oder Betriebsmodi (z.B. Stufe 1 /2, Kühlung Ein/Aus).

Die verfügbaren und zur Regelung der RLT-Anlage notwendigen Zustands- und Stellgrößen liegen i.d.R. innerhalb der Systemgrenzen. Abhängig von der Regelstrategie ist es jedoch auch möglich, dass die Konditionen der Raumlufte (Temperatur, Feuchte,

CO<sub>2</sub>-Konzentration) mit einbezogen werden. Beispielsweise wird häufig ein Mittelwert der Ab- und der Raumlufttemperatur berechnet, um die erforderliche Soll-Zulufttemperatur zu bestimmen. Da die genannten Zustandsgrößen außerhalb der Systemgrenzen liegen kann sich hier das dynamische Verhalten hinsichtlich der Zeitkonstante signifikant von den übrigen Größen unterscheiden. Zudem können auftretende Fehler-Symptome durch andere Komponenten der TGA verursacht werden. Eine Raumlufttemperatur unterhalb der Sollwertvorgaben kann bspw. durch den Ausfall des statischen Heizsystems verursacht werden und ist in diesem Fall nicht auf ein Fehlverhalten der Lüftungsanlage zurückzuführen. Dies kann das FED-System sowohl im Prozess der Fehlererkennung als auch in der Diagnose vor eine besondere Herausforderung stellen.

### 2.7. Mögliche Fehlerquellen in RLT-Anlagen

Analog zu anderen Teilsystemen in der technischen Ausrüstung von Gebäuden (Wärmeübergabestationen, Heizkörper mit Thermostatventil, Heizkessel, etc.), bilden raumlufttechnische Anlagen geschlossene Regelkreise. Abbildung 10 zeigt die Dekomposition des Gesamtprozesses in seine regelungstechnischen Komponenten sowie mögliche Fehlerquellen.

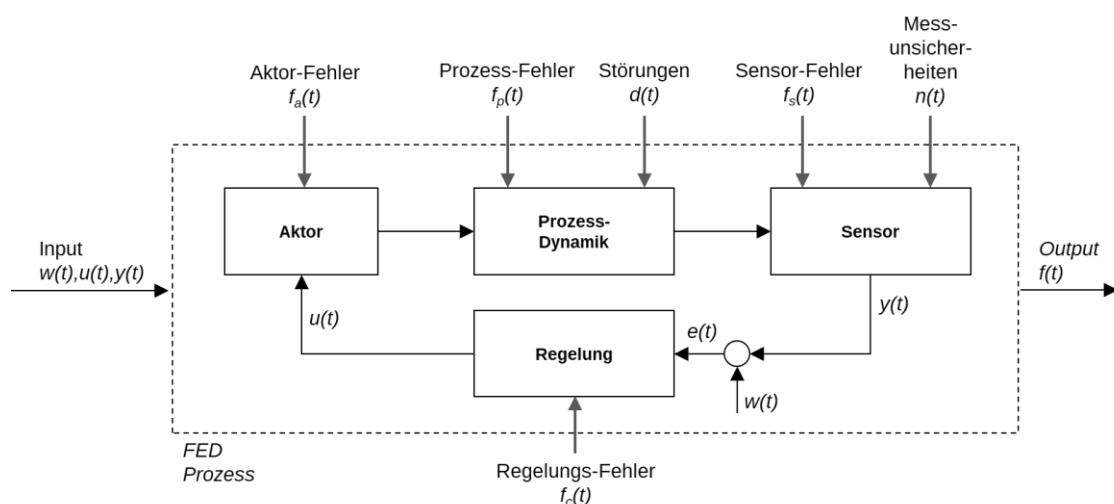


Abbildung 10: Strukturelle Zerlegung eines Systems und mögliche Quellen von Fehlern.

Fehler können sowohl durch externe Einflüsse, wie z.B. den Ausfall der Wärmeversorgung, aber auch durch interne Ursachen, wie z.B. ein feststehendes Stellventil, auftreten und einen Betriebsausfall oder -störung verursachen. Diese Fehler  $f(t)$  wirken auf die Prozessparameter  $\Theta$  oder die internen Zustandsgrößen  $x(t)$  und beeinflussen damit in Abhängigkeit der Systemcharakteristik die observierten Ausgangsgrößen  $y(t)$ . Hier-

bei ist jedoch zu beachten, dass nicht nur die Fehler, sondern auch die auf den Prozess wirkenden äußeren Einflüsse (Störungen)  $d(t)$ , die Messunsicherheiten  $n(t)$  und die Stellgrößen des Reglers  $u(t)$  zu einer Veränderung der Ausgangsgröße führen. Ein zuverlässiges Fehlerdiagnosesystem sollte daher in der Lage sein, Fehler von Prozessstörungen und Messunsicherheiten zu unterscheiden. Genauer gesagt, das Fehlerdiagnosesystem muss gegenüber diesen Unsicherheiten robust und gleichzeitig empfindlich gegenüber Fehlern sein.

In offenen Regelkreisen führen Fehler  $f(t)$  zu einer direkten Abweichung der Ausgangsgrößen  $\Delta y(t)$ . Geschlossene Regelkreise verhalten sich hingegen anders. In Abhängigkeit der zeitlichen Veränderung der Prozessparameter  $\Delta\theta(t)$  oder der Zustandsgrößen  $\Delta x(t)$  können nur kurzzeitige Abweichungen der Ausgangsgrößen beobachtet werden. Der Grund hierfür ist, dass der Regler nicht nur Prozessstörungen und Messunsicherheiten kompensiert, sondern auch die Fehlereinflüsse. Vorausgesetzt, dass der zulässige Betriebsbereich nicht verlassen wird, führen Fehler in einem geschlossenen Regelkreis damit vorrangig zu einer Abweichung der Stellgrößen  $\Delta u(t)$ . Für eine Überwachung des Gesamtprozesses ist es daher notwendig neben den Ausgangsgrößen auch die Stellgrößen zu erfassen und in den Analyseprozess einfließen zu lassen [48].

Der zu überwachende Gesamtprozess kann strukturell in vier Teile gegliedert werden: Aktoren, Prozessdynamik, Sensoren und Regelung. Entsprechend dieser Gliederung werden die möglichen Fehlerquellen wie folgt klassifiziert:

(i) **Aktorfehler:**

In elektromechanischen Systemen wandeln Aktoren (oder Stellglieder) die elektronischen Signale des Reglers in mechanische Signale und nehmen hierdurch direkt Einfluss auf das Prozessverhalten. Die Folgen von Aktorfehlern können sich unterschiedlich auswirken, von einem erhöhten Energieverbrauch (Eingeschränkter Betriebsbereich eines Aktors) bis hin zu einem vollständigen Kontrollverlust (Totalausfall eines Aktors). Die möglichen Fehlertypen und deren zeitlichen Charakteristiken sind stark abhängig vom beobachteten Aktortyp. Es können jedoch für bestimmte Gruppen gemeinsame Fehlerarten identifiziert werden. Beispielsweise sitzen Regelventile häufig in einer bestimmten Position fest oder sie schließen nicht vollständig, sodass eine Leckage beobachtet werden kann.



### (ii) **Prozessfehler:**

Prozess- oder Komponenten-Fehler führen zu Veränderung im dynamischen Verhalten des zu regelnden Prozesses und somit zu veränderten Systemgleichungen im Vergleich zum fehlerfreien Betrieb. Die mathematische Darstellung oder die Modellierung dieser Fehler sind häufig sehr schwierig und erfordern vor der Erstellung möglicherweise umfangreiche praktische Versuche. Im Allgemeinen können Prozessfehler durch eine Änderung der Zustandsgleichung des Systems dargestellt werden, wobei es sich entweder um eine parametrische Änderung oder eine strukturelle, bzw. funktionale Änderung handelt. Als Beispiel in Lüftungsanlagen können verstopfte Luftfilter, verschmutzte Wärmeübertrager oder ein Lagerschaden im Ventilator genannt werden.

### (iii) **Sensorfehler:**

Sensoren übermitteln Informationen über das Verhalten des Systems und seine internen Zustände. Daher können Sensorfehler die Leistung der implementierten Regeleinrichtung und damit die ordnungsgemäße Funktion erheblich beeinträchtigen. Sensorfehler lassen sich abhängig von ihrer zeitlichen Charakteristik in systematische Fehler (Bias), Drift, Performancedegradation (zunehmende Unsicherheiten), Einfrieren (konstanter Messwert) oder Kalibrierungsfehler gliedern. In Lüftungsanlagen werden vorrangig die Zustandsgrößen wie Temperatur, Feuchte, Druck und Gaskonzentration (bspw. CO<sub>2</sub> Konzentration) der geförderten Luft an unterschiedlichen Positionen im Gesamtprozess erfasst. Hinzu kommen Sensoren in den versorgenden Wasserkreisläufen (bspw. Vorlauftemperatur) und ggf. ergänzende Messwerte außerhalb der Systemgrenze wie die Außenluft- und/oder Raumluftbedingungen.

### (iv) **Regelungsfehler:**

Regelungsfehler zeichnen sich durch einen gegenüber dem nominalen Zustand veränderten funktionalen Zusammenhang zwischen Ein- und Ausgangsgrößen des Reglers aus. In der Praxis sind echte Regelungsfehler jedoch selten und machen sich i.d.R. durch einen Totalausfall des Reglers oder defekten Ausgangsmodulen bemerkbar. Häufiger ist hingegen eine fehlerhafte Parametrisierung der Regeleinrichtung durch das betreuende Fachpersonal. Hierbei handelt es sich jedoch nicht um einen Fehler im technischen System, sondern vielmehr um einen ungewünschten Betriebszustand aufgrund der gewählten Regelparameter. Insbesondere im Gebäudebereich mit einer Vielzahl unterschiedlicher Anlagenkonfigurationen, Betriebszuständen und wechselndem verantwortlichem Personal sind Bedienfehler häufig zu beobachten. Das automatisierte Erkennen von Bedienfehlern kann sich methodisch signifikant unterscheiden und liegt nicht im Fokus dieser Arbeit. Dennoch ist es anzustreben ungewollte Se-

## 2. Fehlererkennung und Diagnose in gebäudetechnischen Anlagen

---

quenzen, die einen ineffizienten Betrieb zur Folge haben, zu identifizieren und als einen fehlerhaften Betriebszustand zu erkennen. Beispiele hierfür sind ein gleichzeitiges Heizen und Kühlen der Zuluft oder ein Heizbetrieb ohne Wärmerückgewinnung.

Neben einer Gliederung hinsichtlich der Fehlerquelle, können Fehler auch bezüglich ihrer mathematischen Wirkung im System charakterisiert werden. Sensor- oder Aktorfehler und Verluste im System (bspw. Undichtigkeiten im Rohrleitungssystem) haben meist eine additive Charakteristik, während Veränderungen in den Prozessparametern (Prozessfehler) i.d.R. multiplikativ wirken. Auch haben Fehler unterschiedliche zeitliche Eigenschaften. Während ein Ventilfehler abrupt (festsitzend) oder wiederkehrend, bspw. bei einem Kontaktfehler der Steuerleitung oder eingeschränkten Arbeitsbereich, auftreten kann, führt z.B. ein Sensordrift meist zu einem langsamen, stetig ansteigenden Verhalten der Fehlergröße.

Im ganzheitlichen FED-Prozess werden Fehler im Betrieb möglichst automatisch detektiert, lokalisiert sowie der Fehlertyp und dessen Auswirkungen bestimmt. Die Hauptaufgabe der Fehlerdiagnose ist es, den gefundenen Fehler zu isolieren und den oben genannten Fehlertypen zuzuordnen und entsprechende Handlungsempfehlungen abzuleiten. Eine besondere Herausforderung ist die Isolierung von mehreren, gleichzeitig auftretenden Fehlern. Da sich in diesem Fall die Fehlersymptome überlagern, ist eine differenzierte Zuordnung zu einzelnen Fehlertypen nur schwer möglich.

## 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

Das Ziel dieser Arbeit ist die Entwicklung eines möglichst automatisierten ganzheitlichen Fehlererkennungs- und Diagnose- (FED-) Ansatzes für den Einsatz in der Heizungs-, Lüftungs- und Klimatechnik in Gebäuden (vgl. Kapitel 1). Um dies zu erreichen werden möglichst selbstlernende Methoden basierend auf historischen Betriebsdaten eingesetzt. Dadurch soll insbesondere der Modellierungs- und Implementierungsaufwand reduziert sowie ein hohes Maß an Übertragbarkeit gewährleistet werden.

### 3.1. Konzept und Gliederung des Gesamtprozesses

In der Anwendung kann ein breites Spektrum hinsichtlich Verfügbarkeit und Eigenschaften der Betriebsdaten aus RLT-Anlagen beobachtet werden. Abhängig von der Anlagenkonfiguration, der Regelstrategie, dem Betreiber, der Wartungsfirma und dem Anlagenhersteller können beispielsweise die Anzahl der Datenpunkte, die Datenpunktbezeichnungen, die Aufzeichnungsintervalle und die Einheiten stark variieren. Voraussetzung für eine automatisierte Auswertung und Interpretation der Betriebsdaten, sowie die Anwendung von Methoden aus dem Bereich des maschinellen Lernens (ML), ist demzufolge eine standardisierte Vorverarbeitung der Daten. Dieser Prozessschritt (Abschnitt 3.2) bildet die Grundlage im entwickelten und in Abbildung 11 schematisch dargestellten FED-Entwurf.

Auch wenn die historischen Betriebsdaten des observierten Systems in einer hohen Qualität (langer Zeitraum, eine große Anzahl von Datenpunkte, hohe Auflösung und wenig Datenlücken oder Ausreißer) vorliegen, besteht in der Praxis das Problem, dass nur kleine Anteile im fehlerhaften Betriebszustand in den Datensätzen enthalten sind. Insbesondere das gesamte mögliche Fehlerspektrum wird nicht abgebildet. Ein direktes Erlernen des fehlerhaften Betriebsverhaltens und/oder Klassifizieren von fehlerhaften Betriebszuständen ist mit datengetriebenen Methoden daher nur begrenzt möglich. Im Residuen-generierenden FED-Ansatz (Abschnitt 2.3) wird hingegen das nominale Verhalten modelliert und es können fehlerfreie Daten für das Modelltraining verwendet werden, die in einem deutlich größeren Umfang vorhanden sind. Vor diesem Hintergrund werden in dieser Arbeit ML-Methoden in einen Residuen-generierenden FED-Prozess eingebettet (Abschnitt 2.3). Dabei ersetzen ML-Modelle das physikalische Systemmodell und berechnen sogenannte Schätzer für die beobachteten Systemgrößen (Abschnitt 3.3).

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

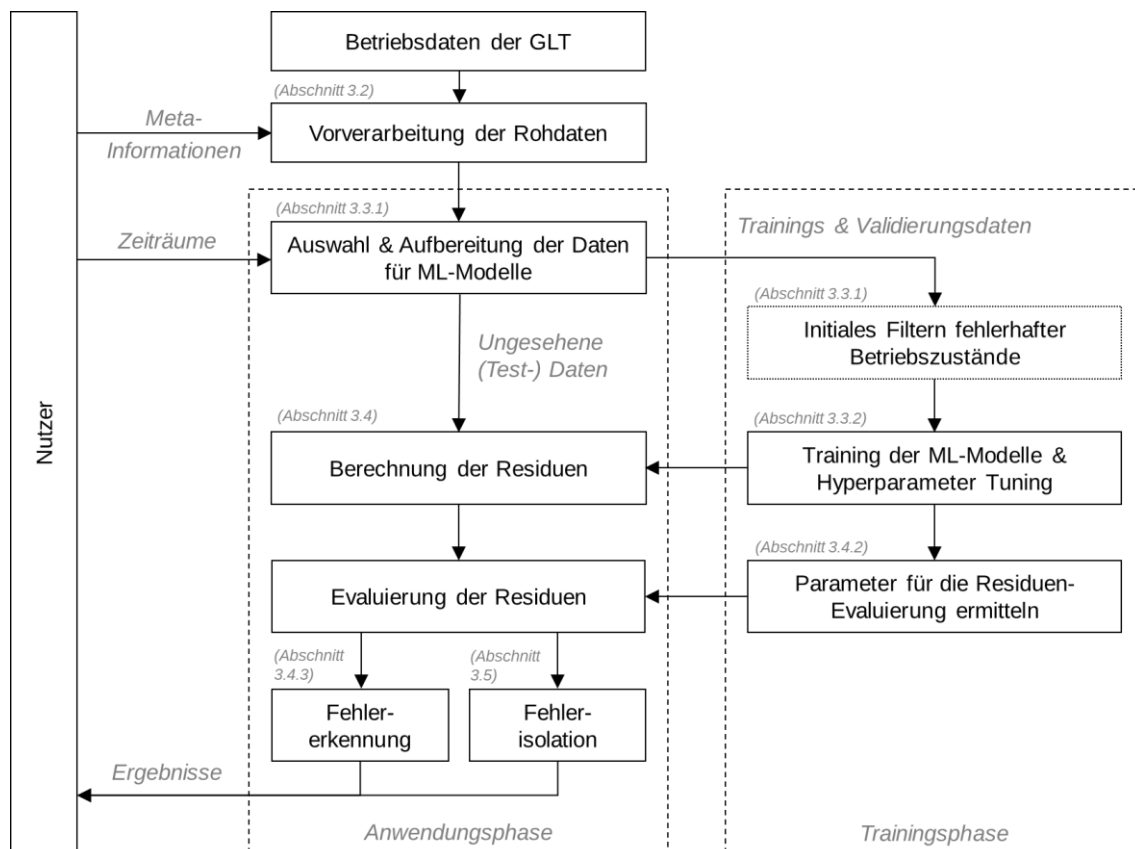


Abbildung 11: Prozessschritte im Residuen-generierenden FED-Entwurf.

Das Ergebnis ist ein Schätzvektor der die Zustands- und Stellgrößen im normalen, fehlerfreien Betrieb des Systems zum Zeitpunkt  $t$  repräsentiert. Auf Basis dieser Schätzungen werden die Residuen zu den observierten Werten bestimmt. Kommt es aufgrund eines Systemfehlers zu Abweichungen im Residuen-Vektor, kann dieser Fehler erkannt und die Auswirkung auf Basis der quantitativen Abweichung analysiert werden. Dabei lässt sich über den Residuen-Betrag auch die Fehlergröße quantifizieren. Die wesentliche Herausforderung im Prozess der Residuen-Evaluierung ist es, das Verhalten der Residuen möglichst sensitive gegenüber Betriebsfehlern und gleichzeitig tolerant gegenüber Modellunsicherheiten zu gestalten. Das Design der Residuen-Evaluierung (Abschnitt 3.4) hat somit einen entscheidenden Einfluss auf Performance des FED-Systems, wird jedoch gleichzeitig in der Literatur selten adressiert (vgl. Abschnitt 2.5).

Sowohl für die Residuen-Generierung als auch die Evaluierung werden die Modellparameter in einer Trainingsphase auf Basis der historischen Betriebsdaten bestimmt. Hierzu werden nutzerdefinierte Zeiträume mit einem möglichst geringen Anteil fehlerhafter Daten oder einer initialen Filterung herangezogen. In der Anwendungsphase

werden die parametrisierten Modelle auf neue, ungesehene Datensätze (Testdaten) für die automatisierte FED angewendet.

Die evaluierten Residuen bilden schließlich die Grundlage für die Fehlererkennung und -isolierung (Diagnose). Im Prozess der Fehlererkennung wird grenzwertbasiert ein binäres Signal anhand der summierten Einzelergebnisse erzeugt (Abschnitt 3.4.3). Die Fehlerisolierung (FI) erfolgt hingegen durch die Zuordnung von Residuen-Mustern zu spezifischen Fehlertypen (Abschnitt 3.5). Final können die im FED-Prozess gewonnenen Ergebnisse in das Facility Management (Nutzer) eingebunden werden und dazu beitragen, einen kontinuierlich fehlerfreien, energieeffizienten Betrieb sicherzustellen und notwendigen Wartungsarbeiten hinsichtlich Personal- und Materialaufwand zu planen.

#### **3.2. Vorverarbeitung der Rohdaten aus der Gebäudeautomation**

Die Betriebsdaten von gebäudetechnischen Daten können abhängig von den genutzten Feldbussen und dem Hersteller der eingesetzten Regelungstechnik in unterschiedlichsten Formaten vorliegen. Die Aufgabe eines übergeordneten FED-Systems besteht darin, diese Daten nutzbar zu machen und für eine automatisierte Auswertung zu standardisieren, sowie eine Mindestqualität sicherzustellen. Moderne Systeme ermöglichen hierzu i.d.R. einen direkten, oft webbasierten Datenaustausch über eine Programmierschnittstelle (englisch.: application programming interface, API) oder Datenbankabfragen. Alternativ ist es meist möglich, die Daten in lesbare, nicht binäre Textdateien zu exportieren.

Diese sogenannten Rohdaten beinhalten Informationen über den Zeitpunkt der Datenerfassung (Zeitstempel), den zugehörigen Wert und eine einmalig vorkommene Datenpunktbezeichnung bzw. Identifikationsnummer (ID). Meist nicht enthalten sind erweiterte, sogenannte Meta-Informationen mit einer individuellen Beschreibung hinsichtlich der Anlagenzugehörigkeit, dem Teilsystem, der Position, Datentyp, Einheit, Wertebereich, etc. Diese Informationen werden jedoch für eine konsistente Analyse und automatisierte Verarbeitung benötigt und müssen oft aus der Datenpunktbezeichnung und vorhandenen Planungsunterlagen in zeitintensiver Arbeit zusammengesucht oder mit Expertenwissen manuell anhand der Daten interpretiert werden. Hierzu zählt auch eine Plausibilitätsprüfung der zeitlichen Verläufe. Dieser Arbeitsschritt ist ein wesentliches Hemmnis in der Wertschöpfungsketten von gebäudetechnischen Betriebsdaten. Für ein effizientes Management von Betriebsdaten aus Gebäuden ist es daher unverzichtbar, dass bereits in der Gebäudeautomation (GA) oder beim Export der Daten stan-

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

---

standardisierte, herstellerunabhängige Bezeichnungen verwendet werden. Auch wenn hierzu bereits Initiativen mit Beteiligung aus der Industrie existieren, zeigt die Praxis ein diverses Bild mit häufig individuell gewählten und z.T. abstrakten Kennzeichnungen.

In dieser Arbeit wird zu diesem Zweck eine projekt- oder gebäudespezifische Sensorliste verwendet. Diese Liste beinhaltet neben einer textlichen Beschreibung des Datenpunktes sogenannte Metadaten wie Sensortyp, Einheit, Messintervall, Systemzugehörigkeit, etc. und generiert aus diesen Angaben eine Standard-Datenpunktbezeichnung. Die hier angewendete Systematik erfolgt in Anlehnung an das *Buildings Unified Data point naming schema for Operation management* (BUDO-Schema), welches von einem Team des Fraunhofer ISE und des E.ON ERC entworfen wurde [49]. Dieser Ansatz ist für die Entwicklung eines FED-Ansatzes zweckmäßig, wird den heutigen allgemeinen Anforderungen im IIoT (industrial internet of things) jedoch nicht gerecht. Um die Hürden in der Wertschöpfungskette von Betriebsdaten aus Gebäuden zu vereinfachen, gibt es aktuelle Pilot- und Forschungsprojekte, die moderne, objektorientierte und herstellerübergreifende semantischen Modelle entwickeln. Hervorzuheben ist das Projekt „Haystack“<sup>6</sup>, welches von einem Konsortium namhafter Hersteller im Bereich der Gebäudetechnik unterstützt wird und ein Tagging-System bereitstellt. Einen Schritt weiter geht das Projekt „Brick“<sup>7</sup> [50]. Hier wird eine schematische Verknüpfung mit Gebäudeinformations- und energetischen Anlagenmodellen, sogenannten digitalen Zwillingen, angestrebt.

Eine semantische Modellierung der Datenpunkte ermöglicht eine automatisierte Verknüpfung der Datenpunkte eines (Teil-)Systems mit einem Modell. Hierzu werden in dieser Arbeit die Datenpunkte einem Template für das Referenzsystem einer RLT-Anlage zugeordnet (siehe Abbildung 12). Das Template<sup>8</sup> repräsentiert eine typische Systemkonfiguration (z.B. Lüftungsanlage mit Wärmerückgewinnung und Heizregister) und definiert die Funktion des Datenpunkts innerhalb des Systems, auf dessen Basis im FED-Prozess standardisierte Analysen (z.B. Regeln) formuliert und angewendet werden können. Beispiele einer solchen Verknüpfung können den Anlagenschemata für die in dieser Arbeit untersuchten Fallstudien (siehe Abschnitt 4, bspw. Abbildung 25) entnommen werden.

---

<sup>6</sup> Projektwebseite: <https://project-haystack.org/> (Juni 2024)

<sup>7</sup> Projektwebseite: <https://brickschema.org/> (Juni 2024)

<sup>8</sup> Hinweis: Die Bezeichner innerhalb des Templates sind in Anlehnung an eine vom Fraunhofer ISE entwickelte Systematik für die Anwendung von Regeln gewählt.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED




Abbildung 12: Standardisierte Datenpunktbezeichnungen eines Projektes (links) und Mapping mit einem Systemtemplate für eine RLT-Anlage (rechts).

Mit Hilfe der Meta-Informationen werden die Rohdaten für die weitere Nutzung im FED-Prozess vorverarbeitet. Dabei werden die in Tabelle 6 gelisteten Prozessschritte in genannter Reihenfolge durchgeführt. In jedem der Teilschritte muss beachtet werden, dass eine Veränderung oder Filterung der Rohdaten auch zu einem Informationsverlust führen kann. Beispielsweise sollten die Wertebereiche der Daten lediglich geprüft, die Zeiträume bei einer Grenzüberschreitung jedoch nicht bereinigt werden. Ein veränderter Wertebereich kann durch einen Fehler verursacht sein, sodass einer Filterung dieser Symptome den späteren FED-Prozess erschwert.

Tabelle 6: Schritte in der Vorverarbeitung der Rohdaten aus der Gebäudeautomation.

Verarbeitungsschritt:	Kurzbeschreibung
Sortieren und Entfernen von Duplikaten	Die Daten werden in chronologischer Reihenfolge sortiert und Duplikate entfernt.
Skalierung und Offset	In der Datenpunktliste angegebene Skalierungs- und Offsetfaktoren werden angewendet, um bekannte systemische (dauerhafte) Fehler in der Datenerfassung oder den Wertebereich zu korrigieren.
Konvertierung der Einheiten	Die Einheiten der Betriebsdaten werden standardisiert. Zur Anwendung kommen SI-Einheiten, wobei Leistungen in kW, Energien in kWh und Volumenströme in m <sup>3</sup> /h umgerechnet werden. Stellsignale oder Betriebsrückmeldungen werden in einen Wertebereich von 0-1 konvertiert.
Bereinigung von Zählerdaten	Es wird geprüft, ob die Zählerdaten kontinuierlich ansteigend sind und ggf. auftretende Ausreißer entfernt.
Prüfung des Wertebereiches	Auf Basis der Meta-Informationen wird geprüft, ob die einzelnen Datenpunkte innerhalb eines vorgegebenen Wertebereiches liegen. In diesem Schritt können bereits auffällige Zeiträume identifiziert werden.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

Verarbeitungsschritt:	Kurzbeschreibung
Sampeln der Daten	Die Daten werden in ein einheitliches Zeitraster zusammengeführt (bspw. 10 Minuten), wobei folgende Teilschritte individuell für jeden Datenpunkt angewendet werden: Intervall der Datenaufzeichnung ermitteln, Auswahl und Anwendung einer geeigneten Samplemethode (Mittelwert / Differenz / letzter Wert), ggf. Interpolation der Daten.

Ein wichtiger Teilschritt ist das Sampeln der Daten in ein einheitliches Zeitraster für die Analyse und die Anwendung von ML-Modellen. Hierzu wird zunächst das Logintervall der Rohdaten anhand von mehreren Stichproben ermittelt. Ändert sich das Logintervall innerhalb des Messzeitraums, wird für die weitere Verarbeitung das größere Intervall verwendet. In diesem Schritt wird auch geprüft, ob es sich um sogenannte Eventdaten (Aufzeichnung nur bei einer Werteänderung) handelt. Das Zielintervall wird schließlich so gewählt, dass es dem Log-Intervall für die Mehrheit der Datenpunkte entspricht. Ein zu kleines Intervall erfordert ein systematisches Interpolieren der Daten und kann zu Zeitreihen führen, die nicht dem tatsächlichen dynamischen Verhalten des Systems entsprechen. Hier entsteht insbesondere die Gefahr, dass die ML-Modelle in einem datengetriebenen FED-Ansatz ein falsches Systemverhalten, bzw. das Interpolationsverfahren erlernen. Ein zu großes Ziel-Intervall führt hingegen dazu, dass kurzzeitige Werteänderungen und damit die Systemdynamik nicht mehr im Detail analysiert werden kann. Zwar sollte grundsätzlich eine Interpolation der Daten vermieden werden, jedoch ist es in folgenden Situationen ein probates Werkzeug sein, die Datenverfügbarkeit für das Trainieren von ML-Modellen zu erhöhen:

- (i) Es treten regelmäßige kurze Datenlücken auf, die auf das System der Messdatenerfassung zurückzuführen sind.
- (ii) Einzelne Datenpunkte des observierten Systems werden in einem größeren Zeitintervall erfasst.




Abbildung 13: Beispiel für die Interpolation von Betriebsdaten bei häufigen kurzzeitigen Datenlücken.



In der Datenvorerarbeitung für die betrachteten Fallstudien wird daher maximal über den Zeitraum des zuvor ermittelten Log-Intervalls der Rohdaten linear interpoliert (ein Rohdaten-Zeitschritt). Eine Ausnahme bilden Event-Daten, die den letzten erfassten Wert bis zum nächsten Logzeitpunkt beibehalten („forward fill“).

Die Wahl einer geeigneten Methode für das finale Sampeln der Daten muss individuell für den jeweiligen Datenpunkt erfolgen. Eine falsch gewählte Methode zu einer Fehlinterpretation der Zeitreihen führen. Beispielsweise kann bei einer Mittelwertbildung für diskrete Variablen der Eindruck entstehen, dass in den Zeitreihen Werte zwischen den ursprünglichen Stützstellen vorhanden sind. Die Zeitreihe für ein Stellsignal mit den Werten 0 und 1 kann beispielsweise nach dem Sampeln einen Wert von 0,5 enthalten. Vor diesem Hintergrund können Anwendungsszenarien für drei verschiedene Sample-Methoden formuliert werden:

- (i) Bei kontinuierlichen Größen, wie Temperaturen, Stellsignal von Ventilen, Volumenströme, etc. wird ein Mittelwert über das Zielintervall gebildet.
- (ii) Für kumulierte Größen, wie Zählerdaten, Betriebsstunden, etc., erfolgt eine Berechnung der Differenz.
- (iii) Diskrete Größen, wie der Betriebsstatus (Ein/Aus) oder eine binäre Ansteuerung einer Pumpe (0/1), etc., erfordern hingegen eine Methode, die den letzten vorhanden Wert für das Ziel-Intervall verwendet.

Abschließend werden die mit einheitlichen Zeitstempeln gesampelten Daten des observierten Systems für die weitere Anwendung in einem automatisierten FED-System zusammengeführt.

#### **3.3. Schätzung des nominalen Betriebsverhaltens**

Eine wesentliche Aufgabe im Residuen-generierenden FED-Ansatz ist die Schätzung des nominalen Betriebsverhaltens. Neben der eigentlichen Modellbildung und das Finden geeigneter Hyperparameter (Abschnitt 3.3.2), hat die Aufbereitung und die Auswahl der Eingangsgrößen (Features<sup>9</sup>) (Abschnitt 3.3.1) einen signifikanten Einfluss auf die Qualität der Schätzung von ML-Modellen und ist daher ein wichtiger Bestandteil des Modellierungsprozesses.

---

<sup>9</sup> Als Features (deutsch: Merkmale) werden die Eingangsgrößen eines ML-Modells bezeichnet. Hierbei kann es sich um die im Datensatz vorhandenen, oder daraus abgeleitete Variablen handeln, die die Datenstruktur möglichst gut beschreiben. Techniken für die Auswahl und die Berechnung von neuen Features werden allgemein als Feature-Engineering bezeichnet.

#### 3.3.1. Aufbereitung und Auswahl der Eingangsdaten für das ML-Modell

Methoden zur Feature-Auswahl reduzieren die Anzahl der Eingangsvariablen eines ML-Modells und damit dessen Komplexität sowie die für das Training benötigte Rechenkapazität. Gleichzeitig können durch eine Beschränkung auf wichtige Variablen das Rauschen in den Eingangsdaten reduziert und die Genauigkeit erhöht werden. In der Anwendung von ML-Modellen haben sich für diese Aufgabe statistische Kenngrößen, wie die Berechnung des (Pearson-) Korrelationskoeffizienten etabliert [22]. Hierbei wird eine Normalverteilung der Daten und ein linearer Zusammenhang zwischen den untersuchten Variablen vorausgesetzt<sup>10</sup>. Beide Randbedingungen sind für die Betriebsdaten von Gebäuden nichtzutreffend. Zudem muss eine hohe Korrelation nicht zwingend eine kausale Beziehung in den physikalischen Beziehungen des Systems bedeuten und kann eher zufälligen Ursprungs sein. Alternativ kann die Auswahl auf Basis von Expertenwissen erfolgen. Aber auch dieser Ansatz ist nicht trivial und muss abhängig von Datenverfügbarkeit sowie dem Anlagen- und Regelungskonzept der observierten RLT-Anlagen individuell erfolgen. Hierdurch wird die Übertragbarkeit des FED-Systems eingeschränkt und der Implementierungsaufwand erheblich erhöht. Vor diesem Hintergrund werden in dem vorgestellten Ansatz weitestgehend alle vorhandenen Datenpunkte für die Modellbildung verwendet. Hiermit wird gewährleistet, dass die Fehlersymptome in möglichst vielen Positionen des Schätzvektors sichtbar werden.

Eine Ausnahme bilden bestimmte Variablen, die mit einem erweiterbaren Satz system-spezifischer Regeln gefiltert werden. Dazu gehören unter anderem Energie- und Leistungsdaten, die hauptsächlich aus Gründen der Vergleichbarkeit zwischen den Fallstudien entfernt wurden. Diese Daten sollten jedoch in zukünftigen Forschungsarbeiten, insbesondere mit Fokus auf die Fehlerdiagnose, in den Modellbildungsprozess integriert werden. Ein weiterer Fall betrifft Datenpunkte, für die keine ausreichenden Informationen im Datensatz vorhanden sind, um sie direkt zu schätzen. Ein Beispiel dafür ist das Steuersignal des Füllventils im adiabatischen Kühlsystem, das keine Informationen zur Abschätzung der Luftstromzustände liefert und nur dann genauer geschätzt werden kann, wenn der Füllstand des Tanks erfasst wird.

Darüber hinaus werden Datenpunkte ohne Werteänderung im Trainingszeitraum vom Datensatz entfernt, wenn die Bedingung nach Gleichung (4) erfüllt ist. Hierzu zählen

---

<sup>10</sup> Für dynamische Vorgänge muss eine wesentlich komplexere Analyse der Kreuzkorrelation für unterschiedliche zeitliche Verschiebungen durchgeführt werden.

vorwiegend Datenpunkte, die einen konstanten Sollwerte repräsentieren und somit keine Informationen über das Systemverhalten liefern.

$$\frac{\max(x_{train}) - \min(x_{train})}{\bar{x}_{train}} \leq J_{th} \quad (4)$$

$x_{train}$ :      *Zeitreihe einer Variable für den Trainingszeitraum*  
 $J_{th}$ :         *Grenzwert (Default = 0,1)*

Zeitreihendaten können in kategorisch oder kontinuierlich gegliedert werden. Obwohl die meisten Betriebsdaten in Gebäuden kontinuierlich sind (Temperaturen, Stellsignale von Ventilen, etc.), zeigen einige, wie Signale von Pumpen oder Lüftungsklappen, kategorische Eigenschaften. Dies hat auch Einfluss auf die Modellauswahl. Wenn die maximale Anzahl an eindeutigen Zahlenwerten überschritten wird (Gleichung (5)), wird anstelle eines Regressionsmodells ein Klassifizierungsmodell trainiert, da in diesem Fall genauere Schätzungen erzielt werden können [22].

$$|\{x_i | x_i \in \vec{x}\}| \leq J_{th} \quad (5)$$

$\vec{x}$ :            *Zeitreihenvektor eine Variable*  
 $x_i$             *Element i der Menge des Zeitreihenvektors*  
 $J_{th}$ :         *Grenzwert für die maximale Anzahl Elemente in  $\vec{x}$  (Default = 40)*

In der Arbeit mit realen Datensätzen treten häufig Datenlücken auf, die vor der Anwendung eines ML-Modells entfernt oder aufgefüllt werden müssen<sup>11</sup>. Für das Samplen der Daten in ein einheitliches Zeitraster in der Vorverarbeitung der Daten aus der GA (Abschnitt 3.2) werden kurzzeitige Datenlücken interpoliert. Liegen jedoch weiterhin sogenannter NaN-Werte (engl.: not a number) vor, werden die betreffenden Zeitschritte entfernt, da nur vollständigen Datensätze für das Trainieren der angewendeten ML-Modelle verwendet werden können.

In der Anwendung etablierter Methoden aus dem Bereich des Supervised Learnings auf Zeitreihen ist es vorteilhaft die Daten nach Gleichung (6) in ein gleitendes Zeitfenster zu transformieren (Abbildung 14). Dadurch wird es den Methoden ohne interne Rückkopplung ermöglicht, wiederkehrende Muster und zeitliche Abhängigkeiten zu erlernen. Die Anzahl der Zeitschritte  $n$ , die im gleitenden Fenster liegen, ist abhängig von den dynamischen Eigenschaften des Systems, insbesondere dessen Zeitkonstante, zu wählen. RLT-Anlagen können im Vergleich zu anderen TGA-Systemen als dynamisch eingestuft werden. Die Regelgrößen im System erreichen die vorgegebenen Sollwerte

---

<sup>11</sup>Einzelne ML-Algorithmen, wie *Naive Bayes* oder *k-Nearest Neighbors*, unterstützen auch fehlende Werte (NaN) in den Eingangsdaten.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

i.d.R. im Minutenbereich. Allerdings haben auch die Gebäudestruktur und andere interagierende Komponenten des TGA-Systems mit einem deutlich trägeren Verhalten Einfluss auf die Zustandsgrößen. Für die Fallstudien in dieser Arbeit hat sich ein Zeitfenster von zwei Stunden als zweckmäßig gezeigt.

$$\vec{x}_w(t_j) = [x_1(t_j), x_1(t_{j-1}), \dots, x_1(t_{j-n+1}), x_2(t_j), x_2(t_{j-1}), \dots, x_2(t_{j-n+1}), \dots, x_m(t_j), x_m(t_{j-1}), \dots, x_m(t_{j-n+1})] \quad (6)$$

$x_i(t_j)$ : Eingangsvariable  $i$  zum Zeitpunkt  $t_j$

$\vec{x}_w(t_j)$ : Gleitendes Zeitfenster zum Zeitpunkt  $t_j$

$n$ : Anzahl der Zeitschritte (Default – Zeitfenster = 2 Stunden)

$m$ : Anzahl der Eingangsdaten




Abbildung 14: Schema für die Transformation der Zeitreihen in ein gleitendes Zeitfenster.

Im ausgeschalteten Zustand der RLT-Anlage ändert sich die Charakteristik der beobachteten Daten signifikant. In diesen Zeiträumen werden die Zustandsvariablen maßgeblich durch unbekannte Randbedingungen und nicht durch das Systemverhalten beeinflusst. Um dieses Problem zu lösen, werden nur Daten im eingeschalteten Zustand für das Modelltraining und die weitere Auswertung genutzt. Um den Betriebsmodus zu ermitteln, werden abhängig von den verfügbaren Datenpunkte systemspezifische Regeln genutzt.

Für viele Algorithmen aus dem Bereich des maschinellen Lernens hat eine Normalisierung der Eingangsdaten deutliche Vorteile, da hierdurch die richtige Wirksamkeit der Zielfunktion für den Lernprozess sichergestellt wird, das Optimierungsverfahren i.d.R. schneller konvergiert und eine angemessene Regularisierung der Verlustfunktion zur Vermeidung einer Überanpassung stattfinden kann. Zudem wird durch eine Normalisierung jeder Variable die gleiche Gewichtung zugewiesen und verhindert, dass eine einzelne Variable aufgrund eines größeren Wertebereiches das Modelltraining stärker beeinflusst als andere Variablen. Für die Anwendungen von ML-Modellen existieren unterschiedliche Normalisierungsmethoden, die abhängig von den Eingangsdaten und

Modelltypen unterschiedlich performen. Grundsätzlich kann hierbei zwischen einer einfachen Skalierung in einen Wertebereich zwischen null und eins und einer zusätzlichen Transformation der Verteilung (z.B. hin zu einer Normalverteilung) unterschieden werden. Letzteres erschwert jedoch die Interpretation der Modellergebnisse und hat in den untersuchten Fallstudien zu keiner Verbesserung der Modellperformance geführt, weshalb für die Eingangsdaten eine Min-Max-Methode angewendet wird. Ein wesentlicher Nachteil dieser Methode ist die Anfälligkeit gegenüber Ausreißern und erfordert daher eine sorgfältige Prüfung des vorliegenden Wertebereiches in der Vorverarbeitung der Rohdaten (siehe Abschnitt 3.2).

Final erfolgt die Gliederung des gesamten Datensatz in Trainings-, Validierungs- und Testzeiträume<sup>12</sup> auf der Basis nutzerdefinierter Zeiträume (siehe Kapitel 4 Beschreibung der Fallstudien). Idealerweise erstreckt sich der Trainingsdatensatz über ein gesamtes Jahr, sodass möglichst alle klimatischen Randbedingungen in den Daten enthalten sind und erlernt werden können. Zudem setzt die Generierung signifikanter Residuen im Fehlerfall voraus, dass weitestgehend fehlerfreie Betriebsdaten für das Training der ML-Modelle verwendet werden. Ein manuelles Labeling sowie Filtern der Trainingsdaten können in der praktischen Anwendung jedoch wesentliche Hemmnisse darstellen. Aus diesem Grund ist es zweckmäßig den Residuen-generierenden Ansatz mit einem regelbasierten System zu kombinieren, um initial bekannte und häufig vorkommende Fehler im Trainingsdatensatz zu identifizieren (siehe Abschnitt 3.6). Durch den Einsatz eines hybriden FED-Systems können einerseits ein zuverlässiges Training der ML-Modelle sichergestellt und andererseits unbekannte Fehlertypen erkannt werden.

#### 3.3.2. Modellbildung & Hyperparameter-tuning

Die Schätzung der Zustands- und Stellgrößen für den fehlerfreien Betrieb des Systems erfolgt mit einem Satz von individuellen Regressions- und Klassifikationsmodellen für jede einzelne Variable des Systems. Dabei werden für die Schätzung der  $i$ -ten Zustandsvariablen  $\hat{v}_i$  alle Zustandsvariablen mit Ausnahme des  $i$ -ten Elements, hier als  $\tilde{v}$  bezeichnet, und alle Steuersignale  $\bar{u}$  verwendet. Entsprechend ergeben sich die Eingangsgrößen für die Stellgrößen  $\hat{u}_i$ , wobei  $\tilde{u}$  den Stellgrößen-Vektor ohne das  $i$ -te Element repräsentiert (siehe Gleichung (7)). Mit dem gewählten Ansatz wird verhindert, dass die möglicherweise fehlerbehaftete Variable  $i$  in die eigene Schätzung ein-

---

<sup>12</sup> Der Validierungsdatensatz wird während des Modelltraining zur Anpassung der Hyperparameter verwendet und unterscheidet sich damit zum Testdatensatz, der für die Bewertung der Schätzgüte des finalen Modells zurückgehalten wird (siehe Abschnitt 2.4.2).

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

fließt. Dies stellt einen wesentlichen Unterschied zum Design von Vorhersagemodellen dar, bei denen i.d.R. historische Werte der Schätzgröße als Eingangsvariable genutzt werden, um so eine zeitliche Zunahme (Drift) der Modellabweichung zu vermeiden. Es ist zu beachten, dass die Eingangsgrößen für die Schätzung die vektorielle Darstellung eines gleitenden Zeitfensters repräsentieren (siehe Gleichung (6)). Aus den individuellen Schätzungen ergibt sich ein Schätzvektor  $\vec{\hat{y}}$  für die Gesamtheit der observierten Daten zum Zeitpunkt  $t$  nach Gleichung (8).

$$\hat{v}_i(t) = f(\vec{v}_w(t), \vec{u}_w(t)); \quad \hat{u}_i(t) = f(\vec{u}_w(t), \vec{v}_w(t)) \quad (7)$$

$$\vec{\hat{y}}(t) = [\hat{v}_1(t), \dots, \hat{v}_n(t), \hat{u}_1(t), \dots, \hat{u}_m(t)] \quad (8)$$

- $\hat{v}_i(t)$ : Schätzung für die Zustandsgröße  $i$  des Systems zum Zeitpunkt  $t$   
 $\vec{v}_w(t)$ : Zustandsvariablen des Systems (gleitendes Zeitfenster)  
 $\vec{v}_w(t)$ : Zustandsvariablen ohne das  $i$  – te Element (gleitendes Zeitfenster)  
 $\hat{u}_i(t)$ : Schätzung für die Stellgröße  $i$  des Systems  
 $\vec{u}_w(t)$ : Stellgrößenvektor des Systems (gleitendes Zeitfenster)  
 $\vec{u}_w(t)$ : Stellgrößenvektor ohne das  $i$  – te Element (gleitendes Zeitfenster)  
 $\vec{\hat{y}}(t)$ : Schätzvektor für die observierten Daten  
 $n, m$ : Anzahl der Zustands – und Stellgrößen

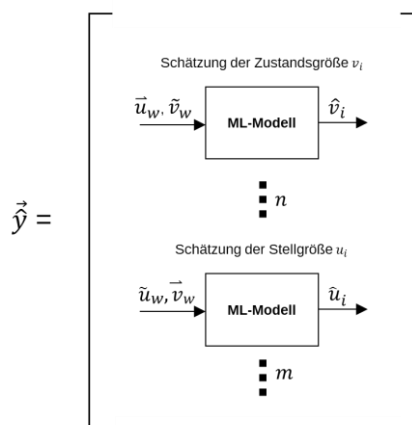


Abbildung 15: Konzeptionelle Darstellung für die Konstruktion des Schätzvektors der Stell- und Zustandsgrößen des observierten Systems.

Für jeden Schätzer wird ein separates Multilayer-Perceptron (MLP) neuronales Netz (NN) trainiert. Es ist zu erwähnen, dass grundsätzlich jede Art von ML-Modell verwendet werden kann, wenn das nominale Verhalten des Systems mit ausreichender Genauigkeit geschätzt wird. Hierbei ist berücksichtigen, dass der Einsatz von komplexeren Modellen nicht automatisch zu besseren Schätzungen führt (vgl. Abschnitt 5.1.1), aufgrund der individuellen Modellierung der Systemgrößen jedoch einen drastischen Anstieg der notwendigen Rechenleistung zur Folge hat. MLPs sind hingegen etablier-

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

---

te, architektonisch einfache, vorwärtspropagierende (feedforward) neuronale Netze. Zudem werden in dieser Arbeit Modell-Architekturen mit einer geringen Anzahl Neuronen und Schichten angewendet (maximal 6 Schichten und 552 Neuronen je Schicht)<sup>13</sup>. Weitere vorteilhafte Aspekte in der Anwendung sind die große Verbreitung dieses Modelltyps und hohen Verfügbarkeit von Werkzeugen für die Modellerstellung.

Eine Aktivierungsfunktion verleiht einem Neuron innerhalb des NN eine nicht-lineare Eigenschaft und ermöglicht damit die Modellierung nicht-linearer Zusammenhänge (siehe Abschnitt 2.4). Während für diskrete Größen ein klassifizierendes MLP NN trainiert wird, das sich durch eine Softmax-Aktivierungsfunktion in der Ausgabeschicht kennzeichnet, werden für Regressionsgrößen MLP NN mit ReLU-Aktivierungsfunktionen in allen Schichten konstruiert. Um eine Überanpassung des Modells an den Trainingsdatensatz zu vermeiden, werden zufällig einzelne Neuronen im Trainingsprozess ausgelassen (Dropout). Zudem wird das Training vor dem Erreichen der maximalen Epochenanzahl abgebrochen, wenn keine Verbesserung der Modellperformance durch die Evaluierung der Verlustfunktion über den Validierungszeitraum zu erkennen ist. Tabelle 7 gibt einen Überblick über die verwendeten Hyperparameter (siehe hierzu auch die Erläuterungen in Abschnitt 2.4).

*Tabelle 7: Gewählte Hyperparameters für das Trainieren der MLP. Parameter, für die ein Wertebereich angegeben ist, werden durch eine Bayes'sche-Optimierung gefunden.*

<b>Hyperparameter</b>	<b>Wert</b>
Maximale Anzahl Epochen	60
Batch-size	1 Tag
Lernrate	1e-4, 1e-5
Verlustfunktion für Regressionsmodelle	RMSE
Verlustfunktion für klassifizierende Modelle	Kreuzentropie
Anzahl der verdeckten Schichten	3-6, Schrittweite 1
Anzahl Neuronen je Schicht	24-552, Schrittweite 48
Dropout erste Schicht	0,1
Dropout zweite bis letzte Schicht	0,2
Aktivierungsfunktion	ReLu
Skalierungsmethode	Min-Max-Skalierung
Encoder (Klassifizierung)	One-Hot-Codierung

---

<sup>13</sup> MLP-Netzwerke können zwar grundsätzlich dem Deep Learning zugeordnet werden, jedoch werden diesem Begriff in der Regel Modelle mit deutlich höherer Komplexität assoziiert.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

---

Die Suche nach einer geeigneten Modellstruktur (Anzahl der Neuronen und Schichten) und anderen Hyperparametern erfordert eine Expertise im Bereich des ML und ist in der Praxis eine arbeitsintensive Aufgabe. Um den Prozess zu automatisieren, werden wichtige Hyperparameter wie die Lernrate, die Anzahl der Schichten oder die Anzahl der Neuronen individuell mit Hilfe einer Bayes'schen Optimierung gesucht und durch Default-Werte ergänzt (siehe Tabelle 7).

Für Regressionsmodelle ist die Zielfunktion der Bayes'schen Optimierung die Minimierung der Wurzel des mittleren quadratischen Fehlers (RMSE) nach Gleichung (9) über den Validierungszeitraum.

$$\arg \min \sqrt{\frac{1}{n} \sum_{t=1}^n (y(t) - \hat{y}(t))^2} \quad (9)$$

- $y(t)$ : *Observierter Wert zum Zeitpunkt  $t$  (im Validierungszeitraum)*  
 $\hat{y}(t)$ : *Geschätzter Wert zum Zeitpunkt  $t$  (im Validierungszeitraum)*  
 $n$ : *Anzahl der beobachteten Werte im Validierungszeitraum*

Bei Klassifizierungsproblemen ist der RMSE nicht anwendbar und es wird stattdessen die Kreuzentropie nach Gleichung (10) als Zielfunktion für die Optimierung genutzt.

$$\arg \min \left( -\frac{1}{n} \sum_{t=1}^n \left[ \sum_{j=1}^m q_j(t) * \log(p_j(t)) \right] \right) \quad (10)$$

- $q_j(t)$ : *Observierter (codierter) Wert der  $j$ -ten Klasse zum Zeitpunkt  $t$*   
 $p_j(t)$ : *Geschätzter (codierter) Wert der  $j$ -ten Klasse zum Zeitpunkt  $t$*   
 $n$ : *Anzahl der beobachteten Werte im Validierungszeitraum*  
 $m$ : *Anzahl der kategorischen Klassen im Validierungszeitraum*

#### 3.4. Berechnung und Evaluierung der Residuen

Der Residuen-generierende FED-Ansatz besteht im Wesentlichen aus zwei Schritten: die Erzeugung von Residuen und die Bewertung der Residuen. Für den ersten Schritt bilden die Schätzungen der MLP-Modelle für den nominalen Betrieb (Abschnitt 3.3) sowie die beobachteten Daten die Grundlage. Hierbei werden die Residuen gemäß folgender Gleichung (11) berechnet:



$$\vec{r}(t) = \text{MinMax}(-1,1, (\vec{y}(t) - \hat{\vec{y}}(t))) \quad (11)$$

$\vec{r}(t)$ : Residuenvektor  
 $\vec{y}(t)$ : Vektor der observierten Werte  
 $\hat{\vec{y}}(t)$ : Vektor der geschätzten nominalen Werte

Es ist wichtig zu erwähnen, dass die Berechnung mit skalierten Werten zwischen 0 und 1 durchgeführt wird, um sicherzustellen, dass die Größe der Abweichung nicht durch den ursprünglichen Wertebereich beeinflusst wird. Die Residuen können somit einen Wert zwischen -1 und 1 annehmen, wobei der Wert 0 den fehlerfreien Betrieb kennzeichnet. Wird der Trainings- und damit Gültigkeitsbereiche der Modelle verlassen, ist es jedoch möglich, dass die Skalierungsgrenzen überschritten werden. Dies tritt insbesondere bei fehlerhaften oder unbekanntem Betriebsbedingungen auf. Die Höhe des resultierenden Residuen-Wertes hat in diesem Fall keine physikalische Relevanz, wodurch es zulässig ist den Bereich auf -1 bis 1 ohne einen Informationsverlust zu beschränken.

#### 3.4.1. L2-Norm basierte Fehlererkennung

Eine etablierte Methodik für die Erkennung von Betriebsfehlern in einem Residuen-generierenden FED-Ansatz ist der Abgleich einzelner oder aufsummierter Residuen mit einem Grenzwert. Nach Ding [13] eignet sich hierfür die L2-Norm des Residuen-Vektors nach Gleichung (12). Die wesentliche Aufgabe besteht dann darin, einen geeigneten Grenzwert zum Auslösen eines Fehlersignals zu finden. Da die Modellunsicherheiten individuell für ein observiertes System variieren, muss auch der Grenzwert entsprechend angepasst werden. Ein möglicher Ansatz für eine automatisierte Berücksichtigung der Modellunsicherheiten ist die Berechnung des Grenzwertes auf Basis der Standardabweichung für die L2-Norm im fehlerfreien Trainings- und/oder Validierungszeitraum nach Gleichung (13). Untersuchungen hierzu (in Abschnitt 5.2.6) haben jedoch gezeigt, dass zur Vermeidung einer hohen Anzahl Fehlalarme eine individuelle Anpassung des Skalierungsfaktors in einem großen Wertebereich notwendig ist, wodurch die praktische Anwendung erheblich erschwert wird. Gleichzeitig führt ein statischer Grenzwert, der auf eine geringe Fehlalarmrate eingestellt ist, zu einer hohen Toleranz gegenüber Fehlern.

$$\|\vec{r}(t)\|_2 = \sqrt{\sum_{i=1}^n (r_i(t))^2} \quad (12)$$

$$J_{th,L2} = f * \text{std}_{fehlerfrei}(\|\vec{r}\|_2) \quad (13)$$

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

$$FS(t) = \begin{cases} falsch; & \|\vec{r}(t)\|_2 \leq J_{th,L2} \\ wahr; & \|\vec{r}(t)\|_2 > J_{th,L2} \end{cases} \quad (14)$$

- $\vec{r}(t)$ : Residuen – Vektor zum Zeitpunkt  $t$   
 $\|\vec{r}(t)\|_2$ : L2 – Norm des Residuen – Vektors zum Zeitpunkt  $t$   
 $J_{th,L2}$ : Grenzwert für die Fehlererkennung  
 $std_{fehlerfrei}$ : Standardabweichung im Auswertezeitraum  
 $f$ : Skalierungsfaktor  
 $FS(t)$ : Fehlersignal

#### 3.4.2. Residuen-Scoring mit variablen Toleranzband

Die Grenzen in der Anwendung der L2-Norm basierten Fehlererkennung zeigen, dass eine differenzierte Evaluierung der individuellen Residuen notwendig ist. Mit dem Ziel die Zuverlässigkeit der nachgelagerten Fehlererkennung (FE) und -isolation (FI) zu erhöhen, wird in diesem Abschnitt eine Scoring-Methode mit variablem Toleranzband eingeführt. Unter Berücksichtigung der in Abschnitt 5.2.1 aufgeführten Herausforderungen zielt die Evaluierung-Methodik darauf ab, Werteänderungen, sogenannte Symptome, die durch einen Fehler verursacht werden, zu verstärken und ein mögliches Rauschen aufgrund von Modellunsicherheiten oder Störungen im System zu filtern. Abbildung 16 veranschaulicht den Evaluierungsprozess.

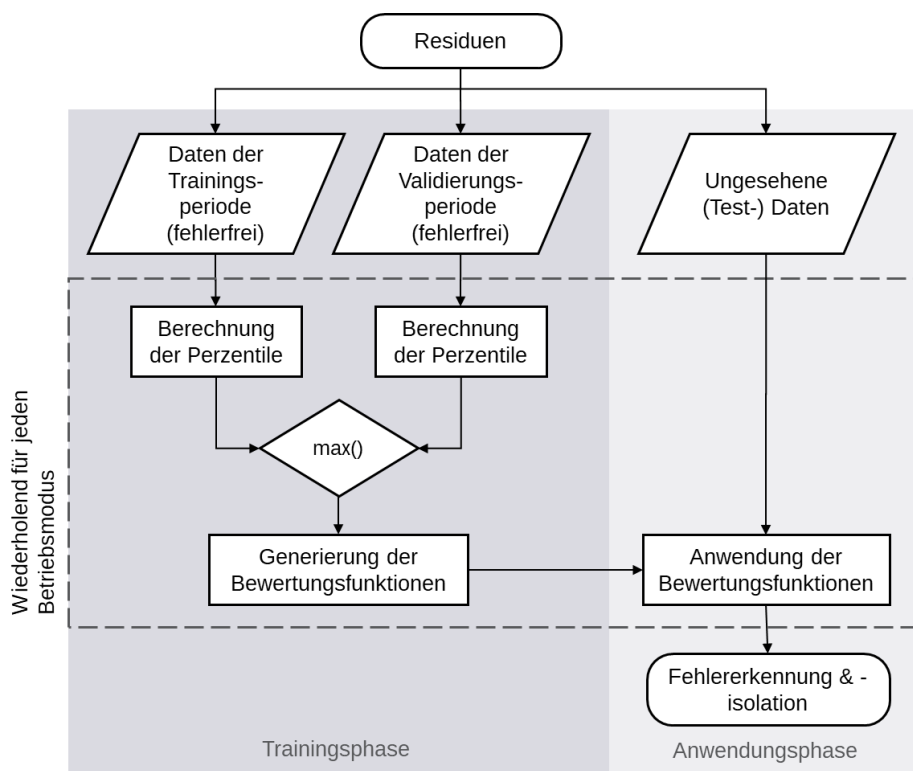


Abbildung 16: Prozessdiagramm für die Evaluierung der Residuen.

Um das normale Betriebsverhalten des Systems zu schätzen (siehe Abschnitt 3.3) und die Residuen zu berechnen, wird das Modell in Trainings-, Validierungs- und Testperioden unterteilt. Die Testperiode repräsentiert dabei die Anwendung auf neue, bisher nicht gesehene Daten. Die gleichen Zeiträume und Datensätze werden auch verwendet, um die Parameter für das Scoring-Verfahren automatisch festzulegen. Dabei ist es wichtig, dass die Daten in den Trainings- und Validierungsperioden möglichst frei von Fehlern sind, um passende Parameter für die Bewertung der Residuen zu finden. Das Verfahren beruht auf einer statistischen Analyse. Es kann zwar einzelne Fehler in den Trainingsdaten tolerieren, jedoch vergrößert sich das Toleranzband mit steigendem Fehleranteil. Dies führt dazu, dass im späteren Prozess weniger Fehler erkannt und isoliert werden können, insbesondere wenn sich in den Trainingsdaten wiederkehrende Fehler desselben Typs befinden.

Das Modelltraining zur Schätzung des nominalen Betriebsverhaltens (siehe Abschnitt 3.3) erfordert die Einteilung der Daten in Trainings-, Validierungs- und Testperioden, wobei Letztere das Anwendungsszenario repräsentiert (ungesehene Daten). Dieselben Zeiträume und Datensätze werden auch zur automatisierten Parametrisierung des Scoring-Verfahrens verwendet. Für diesen Prozess ist es wichtig, dass die Trainings- und Validierungsperioden so fehlerfrei wie möglich sind, um geeignete Parameter für die Residuenbewertung zu finden (siehe Abschnitt 5.2). Das Verfahren beruht auf einer statistischen Analyse und kann einzelne Fehlerzustände in den Trainingsdaten zwar tolerieren, jedoch vergrößert sich das Toleranzband mit einem steigenden Fehleranteil – insbesondere bei wiederkehrenden Fehlern desselben Typs. Dies führt zu einer geringeren Fehlererkennungs- und -identifizierungsrate in den nachgelagerten Prozessen.

Das Scoring der Residuen zielt darauf ab, den Empfindlichkeitsbereich gegenüber Fehlereinflüssen jedes Residuums zu normalisieren und so eine gleichberechtigte Bewertung der Abweichungen zum nominalen Betrieb zu ermöglichen. Die Parameter zur Festlegung der Bewertungsfunktionen sind die Perzentile, die aus der Residuen-Verteilung des Validierungszeitraums abgeleitet werden. Um ein Raster für das Scoring festzulegen, werden insgesamt zehn Perzentil-Ränge heuristisch ausgewählt, die gleichmäßig um den Median verteilt sind (siehe Tabelle 8). Sie bilden die Stützwerte für das Scoring, wobei  $p_1$  das Toleranzband um den Median festlegt (Scoring = 0) und  $p_5$  die obere Grenze bestimmt, ab der ein maximaler Score-Wert zugewiesen wird (Scoring = 1). Zwischen den Perzentilen werden die Scores linear interpoliert (Glei-

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

chungen (17)), sodass die Entfernung zum Median in die Bewertung einfließt. Abbildung 17 veranschaulicht die ermittelten Perzentile und das resultierende linearisierte Scoring anhand exemplarischer Residuen für die Ablufttemperatur einer untersuchten Fallstudie.

$$m_{k,l} = \frac{s_{k,l} - s_{k-1,l}}{p_{k,l} - p_{k-1,l}} \quad (15)$$

$$b_{k,l} = s_{k-1,l} - m_{k,l} * p_{k-1,l} \quad (16)$$

$$s_i(t) = \begin{cases} 0 & \text{falls } p_{1,unten} < r_i(t) < p_{1,oben} \\ m_{k,l} * r_i(t) + b_{k,l} & \text{falls } \begin{matrix} (p_{k-1,oben} \leq r_i(t) \leq p_{k,oben}) \\ \vee (p_{k-1,unten} \geq r_i(t) \geq p_{k,unten}) \end{matrix} \quad \begin{matrix} \text{für } k \ni \{2,3, \dots, n\} \\ l \ni \{\text{oben}, \text{unten}\} \end{matrix} \\ 1 & \text{falls } p_{n,unten} > r_i(t) > p_{n,oben} \end{cases} \quad (17)$$

- $n$ : Anzahl der Stützwerte (Perzentile)
- $k, l$ : Perzentil Nummerierung, Rang – Position (unten/oben)
- $p_{k,l}$ : Perzentil – Wert
- $s_{k,l}$ : Score – Wert für  $p_{k,l}$
- $r_i(t)$ : Residuen – Wert der Schätzgröße  $i$  zum Zeitpunkt  $(t)$
- $s_i(t)$ : Score – Wert der Schätzgröße  $i$  zum Zeitpunkt  $t$

Tabelle 8: Verwendete Perzentile, deren Rang und zugewiesene Score-Werte.

Perzentile	Unterer Perzentil Rang	Oberer Perzentil Rang	Score-Wert
$p_1$	1.50%	98.5%	0.00
$p_2$	0.50%	99.5%	0.25
$p_3$	0.20%	99.8%	0.50
$p_4$	0.10%	99.9%	0.75
$p_5$	0.05%	99.95	1.00

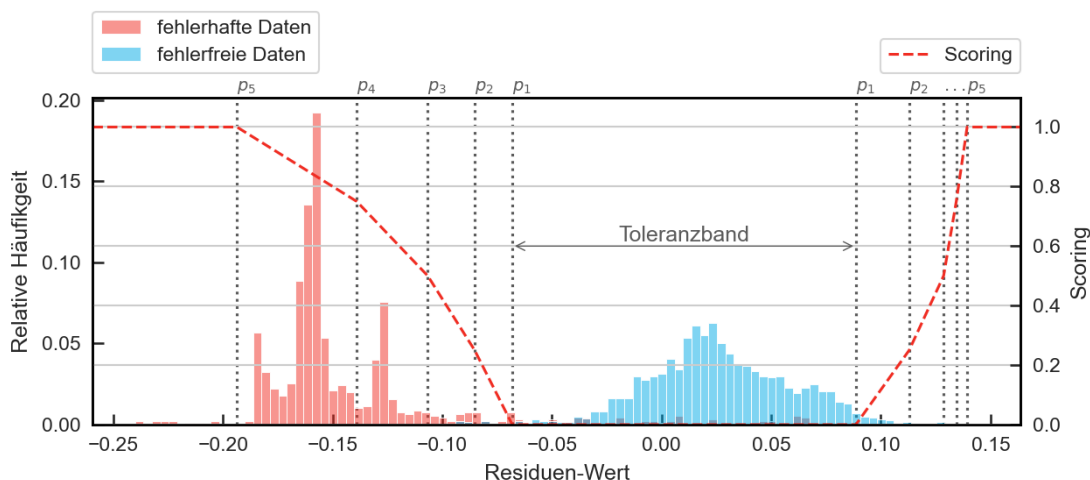


Abbildung 17: Histogramm für die Residuen der Ablufttemperatur im Frischluftbetrieb (MSA, AUD-7, Testzeitraum) für fehlerhafte (rot) und fehlerfreie Datensätze (blau). Die grau gepunkteten Linien zeigen die Perzentile, die für das linearisierte Scoring (rote Linie) verwendet wurden.

ML-Modelle liefern ihre genauesten Schätzungen in der Regel für den Zeitraum der Trainingsdaten. Folglich zeigen die Residuen im Vergleich zum Validierungszeitraum eine geringere Varianz auf. Abhängig von der statistischen Verteilung der Eingangsdaten ist es aber dennoch möglich, dass bessere Schätzungen für den Validierungszeitraum erreicht werden. Um eine angemessene Toleranz bezüglich der Modellunsicherheiten zu gewährleisten, wird überprüft, ob die Perzentile des Trainingszeitraumes tatsächlich kleiner sind. Auf der Grundlage der ermittelten Perzentile werden schließlich die Bewertungsfunktionen erstellt.

$$p_{k,l} = \begin{cases} p_{k,l,eval}, & \text{falls } p_{k,l,eval} \geq p_{k,l,train} \\ p_{k,l,train}, & \text{falls } p_{k,l,eval} < p_{k,l,train} \end{cases} \quad (18)$$

$k, l$ : Perzentil Nummerierung, Rang – Position (unten/oben)

$p_{k,l}$ : Perzentil – Wert

Das beschriebene Verfahren wird für alle observierten Betriebsmodi des RLT-Geräts wiederholt (siehe Abbildung 16), sodass das Toleranzband und die Score-Funktionen abhängig vom Betriebsmodus an die individuelle Residuen-Verteilung angepasst werden. Durch dieses Verfahren wird die Toleranz gegenüber Modellunsicherheiten für Betriebsmodi mit einer schlechten Datenbasis und Schätzung erhöht und eine hohe Fehlalarmrate im FED-Prozess vermieden. Gleichzeitig bleibt das System sensitiv gegenüber Fehlersymptomen in gut erlernten Betriebsmodi.

Für die Generierung des variablen Toleranzbandes wird der aktuelle Betriebsmodus durch einen Satz von Regeln bestimmt, die automatisch auf der Grundlage der verfügbaren Datenpunkte getriggert werden. Der Regelsatz kann die sechs folgenden unterschiedlichen Betriebsarten identifizieren, die den Luftbehandlungsfunktionen der analysierten RLT-Geräte entsprechen:

- Frischluftbetrieb mit Wärmerückgewinnung
- Frischluftbetrieb mit aktiviertem Wärmerückgewinnungs-Bypass
- Heizbetrieb
- Heizbetrieb mit Umluftanteil
- Kühlbetrieb
- und Kühlbetrieb mit Umluftanteil.

Für RLT-Anlagen mit zusätzlichen Komponenten wie Be- oder Entfeuchtung müssen zusätzliche Betriebsszenarien und geeignete Regeln zur Identifizierung definiert werden.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

Ein Zeitreihenbeispiel für das Scoring zeigt Abbildung 18 anhand des Stellsignals für die WRG der RLT-Anlage einer analysierten Fallstudie. Das abhängig vom aktuellen Betriebsmodus (im Betrachtungszeitraum: Ausgeschaltet, Eingeschaltet und Heizbetrieb) variable Toleranzband für den Residuen-Wert wird durch die gestrichelte Linie dargestellt. Die obere Grenze für das linearisierte Scoring kennzeichnet die rote Linie. Die Abweichungen zwischen der Schätzung und den observierten Daten im fehlerfreien Betrieb werden weitestgehend durch das Toleranzband erfasst und mit einem Score-Wert von 0 bewertet. Eine Überschreitung der Toleranzgrenze führt zu einer linearisierten Bewertung der Residuen nach der vorgestellten Methodik. Für das dargestellte Beispiel führt dies im Fehlerfall zum maximalen möglichen Score-Wert ( $S_{WRG-Signal} = 1$ ). Ist die RLT-Anlage ausgeschaltet, erfolgt keine Auswertung der Residuen.

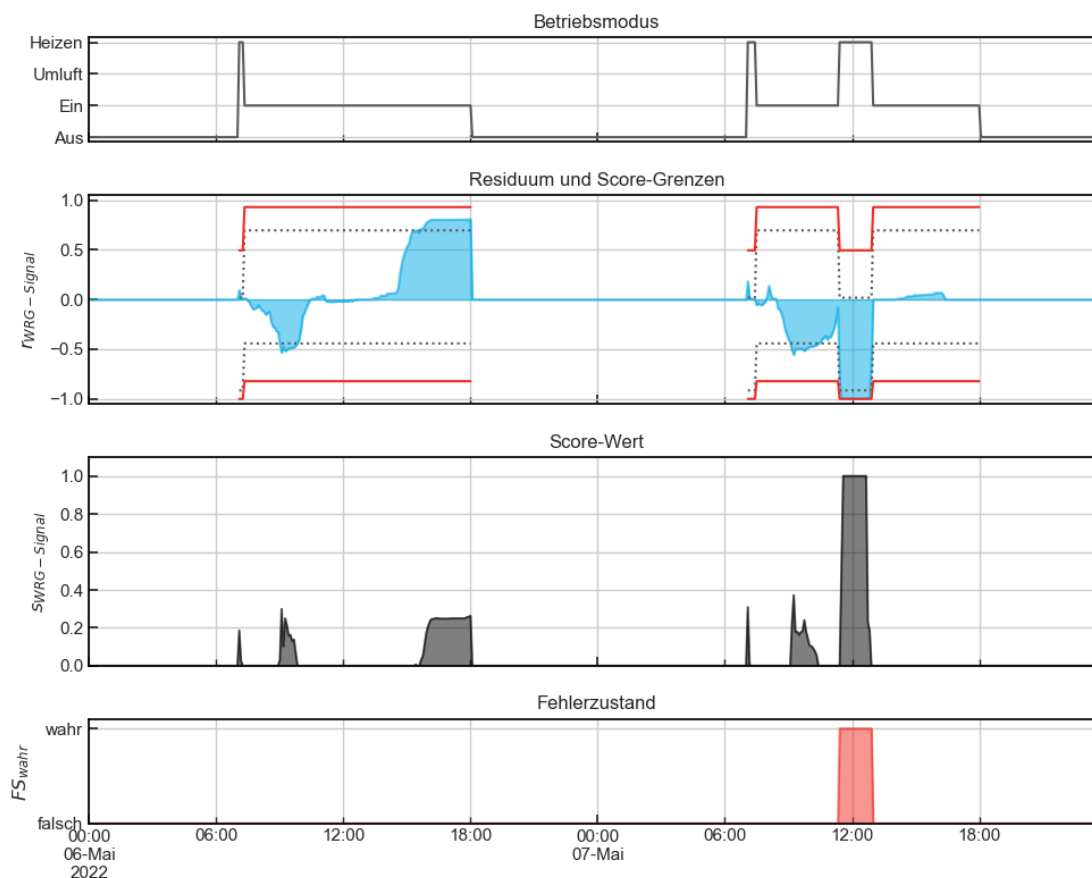


Abbildung 18: Beispiel für das linearisierte Scoring der Residuen anhand des zeitlichen Verlaufs des Stellsignals für die WRG der RLT-Anlage AUD7 im MSA-Gebäude.

#### 3.4.3. Scoring basierte Fehlererkennung

Vergleichbar mit der Fehlererkennung (FE) auf Basis der L2-Norm wird in dieser Arbeit eine FE auf Basis der vorgeschlagenen Scoring-Methode mit einem variablen Toleranzband angewendet. Hierzu werden die Residuen zunächst individuell nach der in Abschnitt 3.4 vorgestellten Methode evaluiert. Schließlich werden die einzelnen Score-Werte zu einem Gesamtscore aufsummiert, um den allgemeinen Systemzustand zu bewerten (siehe Abbildung 19). Überschreitet der Gesamtscore einen vordefinierten Schwellenwert ( $J_{th,s}$ ), wird ein Fehlersignal ( $FSI(t)$ ) getriggert (Gleichung (19)). Der Schwellenwert erlaubt es, die FE-Empfindlichkeit in der Anwendungsphase anzupassen. Anders als bei einer direkten FE basierend auf den Residuen, liegt dieser Schwellenwert durch das implementierte Scoring-Verfahren in einem einheitlichen Wertebereich und erlaubt die Nutzung eines Default-Wertes für die FE. In dieser Arbeit wird systemübergreifend für alle Fallstudien ein Schwellenwert von 1,5 festgelegt.




Abbildung 19: Zeitreihenbeispiel der implementierten Fehlererkennung auf Basis des Scoring-Verfahrens. Dargestellt ist ein Umluftbetrieb der RLT-Anlage AUD7 im MSA-Gebäude ohne aktivierte Heizung oder Kühlung.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

---

Typischerweise treten bei dynamischen Systemen in transienten Zuständen, bspw. wenn das RLT-Gerät von einem Betriebsmodus in einen anderen wechselt, höhere Abweichungen zwischen der Schätzung und den observierten Werten auf. Dies kann in der Anwendung zu häufigen falsch-positive Ergebnissen der FE führen. Daher wird sowohl für den Ansatz basierend auf der L2-Norm als auch auf dem Scoring-Verfahren nur ein Fehlererkennungsalarm ( $FE(t)$ ) ausgelöst, wenn das Fehlersignal länger als zwei aufeinanderfolgende Zeitschritte auftritt (Gleichung (20)).

$$FSI(t) = \begin{cases} \text{wahr, falls } \sum_{i=1}^n s_i(t) > J_{th,s} \\ \text{falsch, falls } \sum_{i=1}^n s_i(t) \leq J_{th,s} \end{cases} \quad (19)$$

$$FE(t) = \begin{cases} \text{wahr, falls } FSI(t) \wedge FSI(t+1) \vee (FSI(t) \wedge FSI(t-1)) \\ \text{falsch, sonst} \end{cases} \quad (20)$$

- $FSI(t)$ : Fehlersignal  
 $s_i(t)$ : Score der Variable  $i$   
 $J_{th,s}$ : Schwellwert für die Fehlererkennung  
 $FE(t)$ : Fehlererkennungsalarm

#### 3.5. Fehlerisolation anhand typischer Residuen-Muster

Abhängig vom auftretenden Fehlertyp prägen sich Residuen in unterschiedlicher Intensität in den individuellen Schätzgrößen aus, sodass charakteristische Residuen-Muster für unterschiedliche Fehlertypen entstehen. Die Aufgabe der Fehlerisolation ist es dann, ein observiertes Muster einem bekannte Fehlertyp zuzuordnen.

Abbildung 20 zeigt exemplarisch das Fehlermuster für den Betrieb mit einem geöffneten Heizregisterventil, ohne dass eine Erwärmung der Zuluft erfolgt (Anlage: FLA, Gebäude: GSHN). Dargestellt sind die Residuen aus den Zeiträumen dieses Fehlertyps als Boxplot. Die Box stellt dabei den Wertebereich von 50 % der Daten dar, während die Antennen 95 % der Daten abdecken und der Median durch die rote Linie markiert wird. Es ist erkennbar, dass dieser Fehlertyp häufig Residuen im Stellsignal des Heizregisterventils ( $U_{HR,Ventil}$ ), in der Zulufttemperatur ( $T_{ZUL}$ ), der Ablufttemperatur ( $T_{ABL}$ ) sowie in der Temperatur im hydraulischen Rücklauf des Heizregister ( $T_{HR,hydRL}$ ) verursacht.



### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

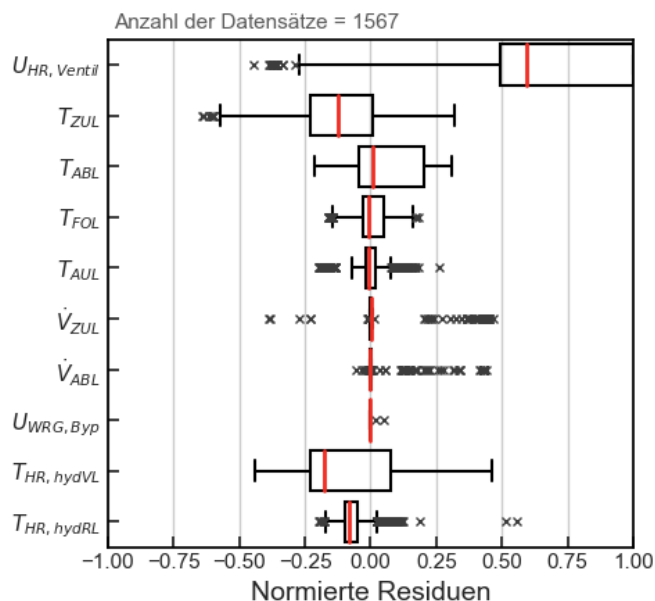


Abbildung 20: Box-Plot-Darstellung für die berechneten Residuen im Fehlerfall. Dargestellt ist das Fehlermuster für den Betrieb mit einem geöffneten Heizregisterventil ohne eine Erwärmung der Zuluft (RLT-Anlage FLA, GSHN-Gebäude).

Treten potenziell mehrere Fehlertypen im Betrieb der observierten Anlage auf, handelt es sich bei der Fehlerisolierung um ein Klassifizierungsproblem mit  $n$  Klassen, wobei sich die Klassenanzahl durch die Anzahl möglicher Fehlertypen ergibt. In der praktischen Anwendung ist die Anzahl möglicher Fehlertypen jedoch unbekannt. Zudem sind nicht für alle Fehlertypen historische Betriebsdaten für das Erlernen typischer Muster verfügbar. Es ist daher zielführend die Fehlerisolierung einzeln für die individuellen Fehlertypen durchzuführen und somit in mehrere Klassifizierungen mit jeweils zwei möglichen Klassen („Fehlertyp liegt vor“ / „Fehlertyp liegt nicht vor“) zu gliedern.

Den umgesetzten Gesamtprozess für die Fehlerisolierung auf Basis der Residuen-Muster veranschaulicht Abbildung 21. Für die Klassifizierung der Fehlermuster werden Random-Forest-Modelle genutzt. Grundsätzlich können jedoch auch andere klassifizierende Modelltypen nach vorheriger Eignungsprüfung eingesetzt werden. Für das Modelltraining werden zunächst die Residuen im fehlerhaften Betriebszustand aus dem gesamten Trainingsdatensatz ausgewählt und mit den, im Labeling-Prozess (siehe Abschnitt 3.6) gefundenen, Fehlertypen verknüpft. Anschließend wird über die vorliegenden Fehlertypen iteriert und die Daten für jeden spezifischen Fehlertyp  $i$  in die Klassen „Fehlertyp liegt vor“ und „Fehlertyp liegt nicht vor“ eingeteilt.

Ein wesentlicher Einfluss auf die Performance von Klassifizierungsmodellen hat das Klassengleichgewicht der Trainingsdaten. In gebäudetechnischen Anlagen treten beobachtete Fehler meist nur temporär auf, was typischerweise zu einem stark unausge-

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

glichenen Verhältnis zwischen den Klassen „Fehler liegt vor“ und „Fehler liegt nicht vor“ führt. Dadurch bevorzugt das eingesetzte ML-Modell oft die Mehrheitsklasse, während die Minderheitsklasse schlechter klassifiziert wird. Ein gängiges und hier eingesetztes Verfahren zur Korrektur des Klassengleichgewichts ist SMOTE<sup>14</sup> [51], bei dem synthetische Datensätze auf Grundlage der Minderheitsklasse generiert werden. Dieses Verfahren erhöht zudem die Varianz der Trainingsdaten und verbessert somit die Generalisierungsfähigkeit des Modells.




Abbildung 21: Prozessdiagramm für das Trainieren und das Anwenden von klassifizierenden Modellen zur Fehlerisolation auf Basis der Residuen-Muster.

Anschließend wird das Modelltraining mit den in Tabelle 10 angegebenen Hyperparametern durchgeführt, wobei die finalen Parameter durch eine Rastersuche und eine Kreuzvalidierung gefunden werden.

<sup>14</sup> Synthetic Minority Over-sampling Technique (SMOTE) nutzt zur Erzeugung der Minderheitsklasse ähnliche, synthetische Datensätze den K-Nearest-Neighbor-Algorithmus.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

---

Dieser Vorgang wird für alle Fehlertypen, die im Trainingszeitraum auftreten, wiederholt. Dadurch entstehen separate Klassifizierungsmodelle zur Identifizierung der jeweiligen Fehlermuster. Diese werden in der Anwendungsphase genutzt, um bei einem positiven Alarm der Fehlererkennung das observierte Residuen-Muster einem bekannten Fehlertyp zuzuordnen. Zudem können die Wahrscheinlichkeiten für eine Zugehörigkeit zur positiven Klasse ausgewertet und eine geordnete Liste potenzieller Fehlertypen erstellt werden. Insbesondere bei uneindeutigen Residuen-Mustern liefert dies zusätzliche Informationen, die bei der Fehlerbehebung hilfreich sein können. Ist keine Zuordnung möglich, handelt es sich um ein unbekanntes Fehlermuster.

*Tabelle 9: Gewählte Hyperparameter für das Trainieren der Random-Forest Klassifikatoren zur Fehlerisolation. Parameter, für die ein Wertebereich angegeben ist, werden durch eine Raster-suche gefunden.*

<b>Hyperparameter</b>	<b>Wert</b>
Methode zur Korrektur des Klassenungleichgewichts	Synthetic Minority Over-sampling Technique (SMOTE)
Methode zum Finden der Hyperparameter	Rastersuche (englisch: grid search)
Kreuzvalidierungsverfahren	k-fache (einfache) Kreuzvalidierung
Anzahl der Teilmengen (k) für die Kreuzvalidierung	5
Modelltyp	Random Forest
Kriterium zum Splitten der Entscheidungsbäume	Gini-Impurity
Anzahl der Entscheidungsbäume	100, 200, 500
Maximale Anzahl Knoten	Keine, 10, 20, 30
Mindestanzahl von Samples für einen Split	2, 5, 10
Mindestanzahl von Samples an einem Blattknoten eines Entscheidungsbaums	1, 2, 4

#### 3.6. Erstellung gelabelter Datensätze

Für die Entwicklung und Bewertung der Ergebnisse automatisierter FED-Methoden ist es notwendig, den tatsächlichen (wahren) Fehlerzustand des beobachteten Systems zu kennen. Darüber hinaus werden für die Fehlerdiagnose möglichst genaue Beschreibungen der vorliegenden Fehlertypen benötigt. Wenn diese Informationen vorliegen, spricht man allgemein von einem gelabelten Datensatz. Grundsätzlich lassen sich vier Techniken zur Generierung gelabelter Datensätze unterscheiden:

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

---

- Simulierte (synthetische) Betriebsdaten, die auf einem mathematisch-physikalischen Systemmodell beruhen
- experimentelle Daten (Hardware-Simulation) aus einer Laborumgebung
- gelabelte (reale) Betriebsdaten eines im Feld befindlichen Systems
- manuelle Fehler-Implementierung in einem realen Datensatz eines Systems (Datenmanipulation)

Simulierte Daten haben den Vorteil, dass gezielt bekannte Fehlerzustände umgesetzt und Datensätze mit einem hohen Anteil fehlerhafter Zustände generiert werden können. Allerdings unterscheidet sich die Charakteristik der Daten – die meist ohne stochastische Effekte erzeugt werden - oft deutlich von realen Betriebsdaten. Insbesondere FED-Methoden, die auf Basis historischer Betriebsdaten trainiert werden, können das simulierte Verhalten meist sehr gut wiedergeben, performen jedoch deutlich schlechter bei der Anwendung auf realen Betriebsdaten. Im Gegensatz dazu ermöglichen Betriebsdaten von Systemen, die im Feld betrieben werden, die Prüfung von FED-Methoden unter realen Anwendungsbedingungen. Jedoch sind hier die Randbedingungen, die Regelungsstrategie und der Fehlerzustand nicht immer eindeutig bekannt, was zu Problemen bei der Entwicklung von FED-Methoden führen kann. Gleichzeitig ist es schwierig, fehlerhafte Zustände während des Betriebs durch einen manuellen Eingriff künstlich herbeizuführen. Um dieses Problem zu lösen, werden in einigen Studien fehlerfreie Betriebsdaten manuell manipuliert, um so eine große Vielfalt an fehlerhaften Betriebsdaten zu erzeugen. Da dieser Ansatz jedoch genaue Kenntnisse über die (sehr komplexen) Auswirkungen von Fehlern voraussetzt, ist dieser Ansatz sehr anfällig für falsche Datenmanipulationen.

Bisher sind nur unzureichend Datensätze für die Entwicklung und Erprobung von FED-Methoden im Bereich von HKL-Systemen verfügbar. Melggaard [15] gibt eine Übersicht in der Literatur verwendeten Datensätzen, wobei in Studien mit Fokus auf RLT-Anlagen vorrangig Datensätze zum Einsatz kommen, die im Rahmen eines ASHRAE-Forschungsprojekt entwickelt wurden [52]. Hierbei handelt es sich um einen Mix simulierter und in einer laborähnlichen Umgebung generierten Daten. Die zugrundeliegenden Systemtypologien entsprechen jedoch nicht den in Europa typischen Anlagen-Konfigurationen.

In dieser Arbeit sollen vorrangig ML-Methoden im ganzheitlichen FED-Prozess zum Einsatz kommen. Vor diesem Hintergrund werden ausgewählte Zeiträume realer Betriebsdaten von insgesamt 17 Lüftungsanlagen aus drei verschiedenen Gebäuden

(siehe Kapitel 4) intensiv analysiert und hinsichtlich des Fehlerzustandes gelabelt. Um den Fehlerzustand der Systeme und den Fehlertyp mit einer möglichst hohen Genauigkeit zu bestimmen, werden folgende Methoden parallel eingesetzt und deren Ergebnisse für das finale Labeln abgeglichen (siehe Abbildung 22):

- **Manuelle Datenanalyse:** Die Relationen ausgewählter Datenpunkte werden in Streudiagrammen (z.B. Zulufttemperatur versus Außenlufttemperatur) dargestellt und Anomalien visuell erkannt. Ergänzend erfolgt eine Analyse der zeitlichen Verläufe durch einen Experten.
- **Einfacher Regelsatz:** Für die in den Datensätzen identifizierten und wiederkehrenden Fehler werden Regeln definiert. Dies unterstützt insbesondere den manuellen FE und verbessert die Qualität der Labels.
- **Experten-System:** In Kooperation mit dem Fraunhofer Institut für Solare Energiesysteme (ISE) werden ausgewählte Datensätze mit einem regelbasierten FED-System (COMETH Rules) [53] analysiert. Das System wurde im Rahmen mehrerer Forschungsprojekte durch das ISE entwickelt und besteht aus einer großen Sammlung von Experten-Regeln für die Betriebsüberwachung von HLK-Anlagen. Auf Basis der verfügbaren Datenpunkte werden die Regeln automatisiert getriggert und ein individuelles, binäres Fehlersignal generiert.
- **KI-Anomalie-Erkennung:** Ergänzend kommt für einzelne Datensätze eine vom Fraunhofer ISE entwickelte KI-Methodik zur Fehlererkennung zum Einsatz. Das System basiert auf zwei komplementären ML-Methoden zur Erkennung von Anomalien in Zeitreihendaten (COMETH AI [54]). Während der Anwendung werden die Ergebnisse der unterschiedlich sensitiven Systeme abgeglichen. Bei einer Diskrepanz wird ein Nutzerfeedback für ein Modell-Update der falsch klassifizierenden Methode genutzt.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED




Abbildung 22: Schema für die eingesetzten Methoden zum Kennzeichnen (Labeln) der Datensätze hinsichtlich des Fehlerzustandes und des vorliegenden Fehlertyps zur Bewertung der Ergebnisse des entwickelten FED-Ansatzes.

Tabelle 10: Übersicht der angewendeten Methoden zum Labeln der Datensätze der untersuchten Fallstudien.

Gebäude	RLT-Anlage	Manuelle Datenanalyse	Einfacher Regelsatz	Experten-System	KI-Anomalie-Erkennung
<b>GSHN</b>	FLA	✓	✓	✓	-
	FLB	✓	✓	✓	-
	FLC	✓	✓	-	-
	FA	✓	✓	-	-
	AULA	✓	✓	-	-
	SPO	✓	✓	✓	-
<b>MSA</b>	AUD2	✓	✓	✓	✓
	AUD4	✓	✓	-	-
	AUD7	✓	✓	✓	✓
	AUD8	✓	✓	✓	✓
	AUD9	✓	✓	✓	✓
	AUD11	✓	✓	✓	✓
<b>ISC</b>	CTA01	✓	✓	-	-
	CTA02	✓	✓	✓	-
	CTA03	✓	✓	-	-
	CTA08	✓	✓	✓	-
	CTA17	✓	✓	✓	-

Tabelle 10 zeigt eine Übersicht der angewendeten Methoden zum Labeln der Datensätze aus den untersuchten Fallstudien (Kapitel 4). Da das finale Prüfen und Zuweisen der Labels sehr zeitaufwendig ist, wurden auf der Grundlage einer manuellen Voranalyse die gelisteten RLT-Anlagen aus den verfügbaren Datensätzen ausgewählt. Hierbei wurde vor allem geprüft, ob ausreichend Daten für das Erlernen des fehlerfreien Verhaltens vorliegen. Für diese Anlagen wurde neben einer manuellen Datenanalyse ein einfacher Regelsatz angewendet. Die Analyse mit einem Expertensystem und einer KI-basierten Anomalieerkennung wurde für eine begrenzte Anzahl von Anlagen durch das Fraunhofer ISE durchgeführt, wobei der Schwerpunkt der Kooperation auf den RLT-Anlagen des MSA-Gebäudes lag. Das Ergebnis dieser Prozedur ist einerseits ein binäres Fehlersignal und andererseits eine eindeutige Kennung zur Identifizierung des beobachteten Fehlertyps. Durch die generierten Labels wird eine Performance-Bewertung der Fehlererkennung und -isolation für den entwickelten FED-Ansatzes ermöglicht.

#### 3.7. Bewertung der FED-Performance

Allgemein gesprochen handelt es sich bei einem FED-Prozess um einen Klassifikator, der die Fehlermerkmale in verschiedene Klassen einordnet. Aus der falschen oder richtigen Zuordnung der Merkmale lassen sich aus der relativen Häufigkeit quantitative Metriken zur Beurteilung ableiten.

Die Fehlererkennung ist ein binäres Klassifizierungsproblem mit zwei Zuständen (ja/nein), für dessen Performance-Bewertung die Gleichungen (21) bis (24) angewendet werden [15]. In Betriebsdaten von gebäudetechnischen Anlagen ist es üblich, dass Anomalien auftreten, die sich auf Verzögerungen im Regelkreis oder/und der eingesetzten Logging-Methode zurückführen lassen. Vor diesem Hintergrund werden ausschließlich Fehlerzustände, die mindestens über zwei Zeitschritte des Logging-Intervalls vorliegen, in der Auswertung berücksichtigt.

$$CR = (T_p + T_n)/N \quad (21)$$

$$MisCR = (F_p + F_n)/N \quad (22)$$

$$FAR = F_p/(F_p + T_n) \quad (23)$$

$$FDR = T_p/(T_p + F_n) \quad (24)$$

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

---

<i>CR</i> :	<i>Klassifizierungsrate</i>
<i>MisCR</i> :	<i>Fehlklassifizierungsrate</i>
<i>FAR</i> :	<i>Fehlalarmrate</i>
<i>FDR</i> :	<i>Fehlererkennungsrate</i>
$T_p, T_n$ :	<i>Werte – Anzahl „richtig positiv“ und „richtig negativ“</i>
$F_p, F_n$ :	<i>Werte – Anzahl „falsch positiv“ und „falsch negativ“</i>
<i>N</i> :	<i>Gesamtanzahl der Auswertungen</i>

Bei der Fehlerisolation (Abschnitt 3.5) handelt es sich hingegen um eine Klassifizierung mit mehr als zwei Klassen. Die Anzahl der Klassen ergibt sich aus der Anzahl möglicher Fehlertypen ( $N_c$ ) sowie einer zusätzlichen Klasse für den fehlerfreien Systemzustand. Die Bewertung der Performance über alle Klassen (global) erfolgt nach den Gleichungen (25) bis (28) [15]. Wird die Performance für individuelle Fehlertypen ausgewertet (lokal) handelt es sich hingegen um eine binäre Klassifizierung und es können, wie bei der Fehlererkennung, die Gleichungen (21) bis (24) herangezogen werden.

$$CR = \frac{T_{p,0} + \sum_{i=1}^{N_c} T_{p,i}}{N} \quad (25)$$

$$MisCR = 1 - CR \quad (26)$$

$$FAR = \frac{\sum_{i=1}^{N_c} F_{p,i,0}}{\sum_{i=1}^{N_c} F_{p,i,0} + T_{p,0}} \quad (27)$$

$$FIR = \frac{\sum_{i=1}^{N_c} T_{p,i}}{\sum_{i=1}^{N_c} (\sum_{j=1}^{N_c} F_{p,i,j} + T_{p,i})} \quad (28)$$

<i>CR</i> :	<i>Klassifizierungsrate (global)</i>
<i>MisCR</i> :	<i>Fehlklassifizierungsrate (Fehlisolationsrate, global)</i>
<i>FAR</i> :	<i>Fehlalarmrate der Fehlerisolation (Klassifizierung eines bekannten Fehlers als unbekannt)</i>
<i>FIR</i> :	<i>Fehlerisolierungsrate (richtige Isolierung eines bekannten Fehlertypen)</i>
$T_{p,0}$ :	<i>Werte – Anzahl „richtig positiv“ der fehlerfreien Klasse</i>
$T_{p,i}$ :	<i>Werte – Anzahl „richtig positiv“ der Fehlerklasse <math>i</math></i>
$F_{p,i,j}, F_{n,i,j}$ :	<i>Werte – Anzahl „falsch positiv“ und „falsch negativ“ der Fehlerklasse <math>i</math> in der geschätzten Fehlerklasse <math>j</math></i>
$N, N_c$ :	<i>Gesamtanzahl der Auswertungen, Anzahl der Fehlertypen</i>

Die Ergebnisse für die Klassifizierungs- und Fehlklassifizierungsrate geben eine gute Einschätzung über die Gesamt-Performance der FED. Bei der Interpretation der Fehlalarmrate (FAR) und Fehlererkennungsrate (FDR) müssen jedoch die Häufigkeit und die Art der in den Zeitreihendaten vorhandenen Fehler berücksichtigt werden. Treten



beispielsweise nur wenige Fehler im Auswertungszeitraum auf, was für reale Datensätze charakteristisch ist, kann die Nichtentdeckung eines einzigen Fehlers die FDR erheblich verringern. Darüber hinaus werden Symptome mit einer hohen Wahrscheinlichkeit aufgrund der Systemdynamik verzögert sichtbar. Dies kann dazu führen, dass der erkannte Zeitraum nicht vollständig mit dem gelabelten Zeitraum übereinstimmt. Da zur Berechnung der Metriken alle Zeitschritte ausgewertet werden, wirkt sich dieser Effekt negativ auf die ermittelten FED-Metriken aus, auch wenn der Fehler grundsätzlich erkannt und richtig zugeordnet wird.

Darüber hinaus ist die Bestimmung des wahren Fehlerstatus und -typs im Prozess des Labelns auch immer mit subjektiven Aspekten behaftet und daher in mehrdeutigen Situationen unpräzise. In diesem Zusammenhang wirkt sich auch die Fehlerdefinition aus. In gebäudetechnischen Anlagen werden ineffiziente Betriebszustände, wie z. B. gleichzeitiges Heizen und Kühlen, häufig durch Auslegungs- oder Implementierungsfehler im Bereich der Regelung verursacht. Auch wenn es sich hierbei um Design- oder Herstellungsfehler (und nicht um ein Betriebsfehler) handelt, ist es in der Praxis jedoch wünschenswert solche Probleme zu erkennen. In dieser Studie werden deshalb auch unzulässige Sequenzen als ein fehlerhafter Betriebszustand markiert.

Zudem gibt eine diskrete Kennzeichnung des Fehlers (Ja / Nein und Fehlertyp) keine Auskunft über die Fehlergröße. Die Erkennung von Fehlern ohne signifikante Auswirkungen auf die Zustands- und Steuerungsvariablen kann eine Herausforderung darstellen, insbesondere in einem Residuen-generierenden FED-Prozess. Für unkritische Systeme wie RLT-Geräte ist es zur Steigerung der Akzeptanz jedoch von Vorteil, wenn Fehler ohne oder mit geringer Auswirkung auf das Systemverhalten systemisch toleriert und somit die Anzahl der Alarme reduziert werden.

#### **3.8. Umsetzung und verwendete Software-Tools**

Die vorgestellte FED-Methodik wird in der Python-Programmier-Umgebung (Version: 3.8.16) unter Anwendung von etablierten Open-Source Bibliotheken entwickelt und umgesetzt. Eine Übersicht der wichtigsten Bibliotheken sowie deren Versionsnummern und Anwendungsgebiete zeigt Tabelle 11. Für die Verarbeitung von Zeitreihendaten und die Erstellung von ML-Modellen sind die, im Bereich der Forschung und Entwicklung etablierten, Bibliotheken *Pandas* [55], *Scikit-learn* [56] und *Keras (Tensorflow)* [57] hervorzuheben.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

---

Tabelle 11: Verwendete Python-Bibliotheken sowie deren Versionsnummer und Anwendungsgebiet.

Bibliothek	Versionsnummer	Anwendungsgebiet
Numpy	1.23.5	Numerische Berechnungen (Vektoren, Matrizen)
Pandas	1.5.3	Verarbeitung von Zeitreihendaten, Sampeln der Daten, Datenimport und -export, Datenspeicherung (HDF5)
Scikit-learn	1.2.1	Vor- und Nachverarbeitung der Daten für die Anwendung der ML-Modelle (Skalierung, Berechnung der Metriken, etc.), Modellbildung für die Fehlerisolation (Random-Forest-Algorithmus)
Imblearn	0.10.1	Korrektur von Klassenungleichgewichten in den Trainingsdatensätzen (SMOTE)
Keras (Tensorflow)	2.10.0	Erstellen und Trainieren von ML-Modellen basierend auf Neuronalen Netzen
Pycaret	3.3.0	Performance-Vergleich unterschiedlicher ML-Ansätze
Pint	0.18	Umrechnung physikalischer Einheiten
Plotly	5.9.0	Grafische Darstellung und Auswertung der Daten
Matplotlib	3.7.1	Grafische Darstellung und Auswertung der Daten
Seaborn	0.12.2	Datenvisualisierung mit dem Fokus auf statistische Auswertungen

Mit dem Ziel den entwickelten FED-Prozess anwendbar zu machen und Untersuchungen hinsichtlich der Übertragbarkeit der Methodik durchzuführen, sind die in dieser Arbeit entwickelten Programm-Module in einer Python-Bibliothek zusammengefasst. Durch eine einfache API sind auch nicht Nicht-Experten im Bereich des maschinellen Lernalers, aber Grundkenntnissen im Umgang mit Python, in der Lage den FED-Prozess anzuwenden. Ein Code-Beispiel zur Verwendung der Bibliothek kann Anhang A2 entnommen werden. Abbildung 9 veranschaulicht den Datenfluss und die umgesetzte objektorientierte Struktur. Hierbei werden sowohl die Betriebsdaten und Meta-Informationen über geeignete Import-Funktionen projektspezifisch (i.d.R. ein Gebäude) in einem HDF5-Dateiformat<sup>15</sup> gespeichert. Die Klasse *System* repräsentiert die observierte gebäudetechnischer (RLT-) Anlage und beinhaltet funktional abgegrenzte Objekte für eine automatisierte Betriebs- und Fehleranalyse. Hierzu zählen:

---

<sup>15</sup> Hierarchical Data Format (HDF) bezeichnet ein Datenformat, welches insbesondere in wissenschaftlichen Anwendungen für die Speicherung großer Datenmengen verwendet wird.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

- das Organisieren und Bearbeiten von Meta-Informationen zum Gebäude, zum Teilsystem und zu den Datenpunkten (*Meta*),
- die Vorverarbeitung und das Samplen der Rohdaten (*Data*, Methodik in Abschnitt 3.2),
- das Erstellen von standardisierten Diagrammen und Auswertungen für eine manuelle Analyse der Daten (*Plot / Analysis*),
- die automatisierte Berechnung neuer Features (wie z.B. Temperaturdifferenzen) auf Basis der verfügbaren Rohdaten, als auch die Auswahl der Features für einen FED-Prozess (*Features*),
- Funktionen zum Labeln der Betriebsdaten (*Labeling*)
- und die Integration von Methoden zur automatisierten Fehlererkennung und Diagnose (*FDD*).

Das letztgenannte Objekt (*FDD*) bindet den Residuen-Generierenden FED-Ansatz (*ResGenFDD*) in den gesamten Analyseprozess ein, wobei auch hier methodisch abgrenzbare Aufgabenbereiche in einer objektorientierten Struktur wie folgt gegliedert sind: Schätzung des nominalen Betriebsverhaltens und Berechnung der Residuen (*Generator*, Methodik in den Abschnitten 3.3 und 3.4), Residuen-Evaluierung und Grenzwertbasierte Fehlererkennung (*Evaluation*, Methodik in den Abschnitten 3.4 und 3.4.1) und Fehlerisolation (*Isolation*, Methodik in Abschnitt 3.5).

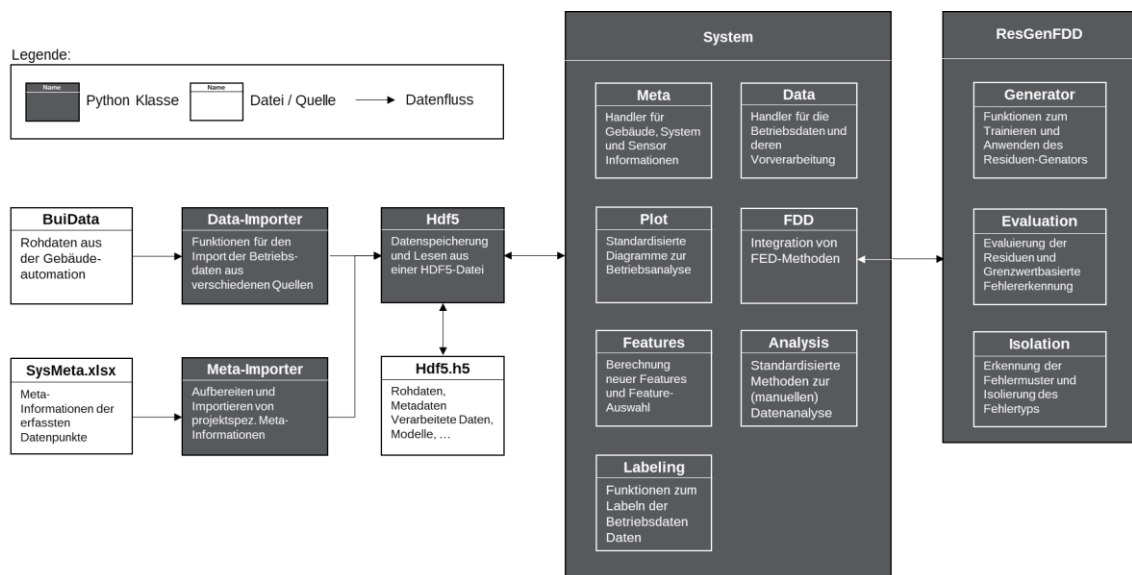


Abbildung 23: Programmstruktur für die entwickelten Python-Module zur Umsetzung des Residuen-generierenden FED-Ansatzes.

### 3. Entwurf einer KI-gestützten und Residuen-generierenden FED

---

## 4. Beschreibung der Fallstudien

Für die Entwicklung und Bewertung der vorgestellten FED-Methodik werden Datensätze von insgesamt 17 RLT-Anlagen aus drei verschiedenen Gebäuden verwendet. Dabei repräsentieren die in diesem Kapitel vorgestellten Fallstudien ein breites Spektrum unterschiedlicher Anlagenkonfigurationen im Bereich der Bildungsbauten. Durch die große Anzahl können Eigenschaften wie Übertragbarkeit, Robustheit gegenüber Fehlalarmen und Parametrisierungsaufwand evaluiert werden. Insbesondere in der Anwendung von selbstlernenden Methoden aus dem Bereich des maschinellen Lernens (ML) ist die Performance stark abhängig von den statistischen Kenngrößen der individuellen Datensätze. Zudem muss die umgesetzte Architektur der FED-Methodik in der Lage sein, sich an die individuellen Randbedingungen (Systemkomponenten, Anzahl und Log-Intervall der Datenpunkte, etc.) des überwachten Systems automatisiert anzupassen.

### 4.1. Grundschule Hohen Neuendorf

Die Grundschule in Hohen Neuendorf (GSHN) ist eine dreizügige Primärschule mit Dreifachsporthalle und einer Aula. Neben der Senkung verbrauchsabhängiger (Energie-) Kosten war wesentliches Planungsziel die langfristige Minimierung der Wartungs- und Instandhaltungskosten. Vor diesem Hintergrund ist das Gebäude als „Low-Tech“ und „Low Cost“ Plusenergie – Grundschule gebaut [58].



Abbildung 24: Südwestansicht der Grundschule Hohen Neuendorf [58].

Tabelle 12: Gebäudekennndaten der Grundschule Hohen Neuendorf.

Standort:	16540 Hohen Neuendorf – Niederheide, Deutschland
Baujahr:	2011
Nutzung:	Grundschule mit Aula und Sporthalle
Beheizte Netto-Grundfläche	6563 m <sup>2</sup>

Das Konzept umfasst:

- eine im Passivhausstandard errichtete Gebäudehülle,
- großflächig verfügbare thermische Speichermasse der Gebäudestruktur für eine freie (Nacht-) Kühlung,

## 4. Beschreibung der Fallstudien

---

- ein Tageslichtnutzungskonzept mit mehrseitigem Tageslichteinfall und ein darauf abgestimmtes Konzept der künstlichen Beleuchtung,
- nachhaltige Energieerzeugung über eine dachintegrierte Photovoltaikanlage und Holzpellets
- sowie ein hybrides Lüftungskonzept zur Reduzierung des elektrischen Energiebedarfes.

### 4.1.1. Lüftungskonzept und -technik

Das Lüftungskonzept der Schule kombiniert eine natürliche (freie) Stoßlüftung über motorisch sowie manuell zu öffnende Fenster und eine mechanische Grundlüftung. Für das Betriebskonzept lassen sich folgende Eigenschaften hervorheben:

- Verlangsamung des CO<sub>2</sub>-Anstiegs in der Unterrichtsstunde durch maschinelle Grundlüftung und Rücksetzen des CO<sub>2</sub>-Gehalts auf Außenluftniveau durch Stoßlüftung in den Pausen über zentral angesteuerte motorische Fensterflügel zur Minimierung ineffizienten Dauerlüftens durch den Nutzer.
- Natürliche Nachtlüftung über motorische Fensterflügel gegen sommerliche Überhitzung zur Komfortsteigerung mit geringem elektrischem Energieaufwand.
- Erhöhte maschinelle Lüftung und Nutzung der Wärmerückgewinnung bei extremen Wittersituationen (Außenlufttemperatur kleiner 0°C oder größer 24°C).

Die Lüftungsgeräte sind für jeden Gebäudeteil dezentral auf dem Dach angeordnet, um die Lufttransportwege kurz und die Anzahl Druckverlust erhöhender Einbauteile (Volumenstromregler, Brandschutzklappen etc.) gering zu halten. Eine Übersicht der Installierten RLT-Geräte, deren Versorgungszonen, Nennvolumenströme und Funktionen ist Tabelle 13 zu entnehmen. Zum Einsatz kommen kombinierte Zu- und Abluftgeräte der Firma HANSA Ventilatoren und Maschinenbau Neumann GmbH mit Plattenwärmetauscher zur Wärmerückgewinnung. Die Zuluft wird über ein Heizregister auf eine Temperatur von 18°C (vor-)erwärmt und in die Klassenräume eingeblasen (Hauptnutzung). Raumseitig wird das System durch ein statisches Heizsystem (Radiatoren) unterstützt. Die Luft aus dem Klassenluft strömt anschließend in den angrenzenden Verkehrsbereich und wird in den Toiletten abgesaugt, wodurch die Luft adäquat zu den hygienischen Anforderungen mehrfach genutzt wird.

Das Lüftungskonzept der Sporthalle sieht eine Dreifachnutzung vor. Die Sporthalle ist auf 3 Spielfelder, die separat gleichzeitig genutzt werden können, aufgeteilt. Für jedes Feld wird die Primärzuluft über Weitwurfdüsen eingeblasen. Die Abluft der Sporthalle

wird unter dem jeweiligen Deckenbereich wieder abgesaugt, über Nacherhitzer erwärmt und als Sekundärluft in die zu jedem Spielfeld zugehörigen Umkleidebereiche geführt. In den an die Umkleiden angeschlossenen Duschen/WCs erfolgt die Abführung der Abluft zur RLT-Anlage. Die Lüftungsleistung für Sporthalle und Umkleiden kann in Abhängigkeit der Belegungsintensität in 3 Stufen reguliert werden.

*Tabelle 13: Akronyme, Versorgungszonen und Eigenschaften der RLT-Anlagen in der Grundschule Hohen Neuendorf.*

Akronym	Zone	$\dot{V}_{Teillast}$ <i>m<sup>3</sup>/h</i>	$\dot{V}_{Volllast}$ <i>m<sup>3</sup>/h</i>	Luftbehandlungsfunktionen*			
				H	K	F	WRG
<b>SPO</b>	Sporthalle und Umkleiden	1740	3780	✓	-	✓	X
<b>AUL</b>	Aula / Mensa	1500	4500	✓	✓	✓	X
<b>FLA</b>	Gebäudeflügel A (Klassenzimmer und Verwaltung)	1650	3150	✓	-	✓	X
<b>FLB</b>	Gebäudeflügel B (Klassenzimmer)	950	2850	✓	-	✓	X
<b>FLC</b>	Gebäudeflügel C (Klassenzimmer und Hort)	950	2850	✓	-	✓	X
<b>FAC</b>	Fachräume	1430	2640	✓	-	✓	X

\* H: Heizen, K: Kühlen, F: Filtern, WRG: Wärmerückgewinnung (X = Kreuzstromwärmetauscher, O = Rotationswärmetauscher)

In der Aula wird neben der WRG und dem Erhitzer auch eine adiabate Verdunstungskühlung eingesetzt, wodurch eine Teilklimatisierung möglich ist. Die Verteilung der Zuluft erfolgt mit Weitwurfdüsen und wird unter der Decke wieder abgesaugt. Die Aula wird für Veranstaltungen, aber auch als Mensa genutzt.

### 4.1.2. Datengrundlage

Im Rahmen eines Forschungsprojektes hat die Hochschule für Technik und Wirtschaft (HTW) Berlin zur Bewertung energetischer und komfortrelevanter Kenngrößen der GSHN ein technisches Gebäudemonitoring durchgeführt [58]. Hierbei wurden u.a. die Betriebsdaten der RLT-Anlagen in einem fünfminütigen Zeitintervall aufgezeichnet. Für das Trainieren der ML-Modelle und die Entwicklung der FED-Methodik werden folgende Zeiträume aus den bereitgestellten Daten verwendet:

- Trainingszeitraum: 01.01.2015 bis 31.12.2015 (12 Monate)
- Validierungszeitraum: 01.01.2016 bis 31.12.2016 (12 Monate)
- Testzeitraum: 01.01.2017 bis 31.12.2017 (12 Monate)

## 4. Beschreibung der Fallstudien




Abbildung 25: Anlagenschema mit einer standardisierten Kennzeichnung der erfassten Datenpunkte für die Lüftungsanlagen FLA, FLB, FLC, FA und SPO in der Grundschule Hohen Neuendorf (GSHN).

Abbildung 25 zeigt exemplarisch ein Prinzipschema der RLT-Anlagen FLA, FLB, FLC, FA und SPO mit einer standardisierten Kennzeichnung der erfassten Datenpunkte. Das Prinzipschema der RLT-Anlage für die Aula enthält zusätzlich ein adiabates Kühlsystem (siehe Anhang A3). Eine Kurzbeschreibung und Übersicht, der für die jeweilige RLT-Anlage verfügbaren Datenpunkte, ist Tabelle 12 in Anhang A4 zu entnehmen. Es lassen sich folgende Datenpunktkategorien zusammenfassen:

- Außenluft-, Abluft-, Fortluft- und Zulufttemperatur
- Stellsignal für das Regelventil, Vor- und Rücklauftemperatur sowie die Wärmemenge im hydraulischen Kreislauf des Heizregisters
- Stellsignale für den Bypass der Wärmerückgewinnung (WRG) sowie der Um- und Außenluftklappen
- Zu- und Abluftvolumenstrom
- Betriebsmodus der Anlage (Aus / Stufe 1 / Stufe 2)
- Elektrischer Energieverbrauch der Anlage
- Ansteuersignal der Umwälzpumpe für die adiabate Kühlung (nur für die Anlage AUL)



Aufgrund des Forschungscharakters des Projektes sind für das Gebäude anlagenspezifische thermische und elektrische Energie- und Leistungsdaten verfügbar. In der Praxis sind diese Daten meist nur für einzelne Anlagen verfügbar und wurden daher für die Entwicklung der FED-Methodik nicht berücksichtigt. Diese können jedoch Gegenstand weiterführender Entwicklungen im Bereich der Fehlerdiagnose sein.

Der Betrieb der RLT-Anlagen im GSHN-Gebäude ist durch einen Heizbetrieb in den Wintermonaten und einem Frischluftbetrieb mit optionalem Bypass der Wärmerückgewinnung (WRG) während der Sommer- und Übergangsmonate geprägt. Die Anteile der Betriebsmodi in den Datensätzen der definierten Zeiträume für das Modelltraining, die Validierung und das Testen sind in Abbildung 26 und Abbildung 27 für die RLT-Anlagen FLB und SPO dargestellt. Identische Diagramme für die übrigen RLT-Anlagen im GSHN-Gebäude können Anhang A5 entnommen werden. Die Anlage FLB repräsentiert die Situation für die Versorgung der Unterrichtsbereiche, die durch einen vorwiegenden Anteil im Heizbetrieb (52% - 63%) geprägt ist. In den Datensätzen der RLT-Anlage SPO überwiegt hingegen der Frischluftbetrieb mit aktivierter WRG (44% - 61%). Für alle Anlagen kann eine annähernd gleichbleibende Verteilung der Betriebsmodi in den Datensätzen mit leichten Verschiebungen aufgrund der schwankenden klimatischen Randbedingungen beobachtet werden. Dies indiziert eine konstante Betriebsweise der Anlagen und Nutzung der Versorgungszonen im Betrachtungszeitraum.

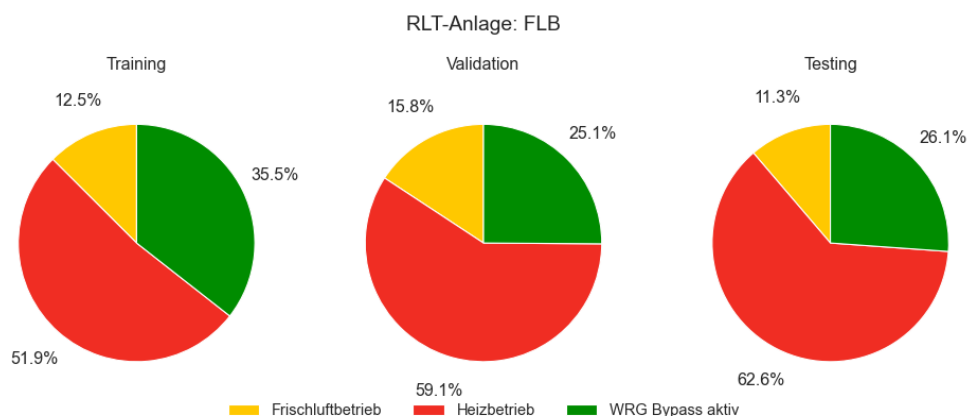


Abbildung 26: Anteile der Betriebsmodi für die RLT-Anlage FLB im GSHN-Gebäude an den Datensätzen für das Training, die Validierung und das Testen.

## 4. Beschreibung der Fallstudien

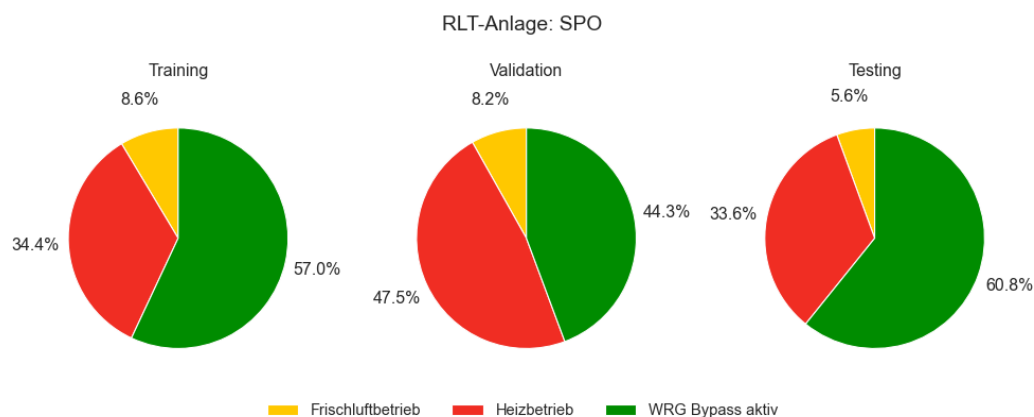


Abbildung 27: Anteile der Betriebsmodi für die RLT-Anlage SPO im GSHN-Gebäude an den Datensätzen für das Training, die Validierung und das Testen.

### 4.2. Maison du Savoir

Das Maison du Savoir (MSA) der Universität Luxembourg auf dem Campus in Esch-Belval wurde 2015 in Betrieb genommen. Der Baukörper (Nettogeschossfläche = 53.560 m<sup>2</sup>) wird durch einen in die Höhe gestemmt Riegel, in dem sich die Hörsäle befinden, sowie einem 18-geschossigen Turm, der unter anderem die Verwaltung der Universität beherbergt, geprägt.

Das Energiekonzept zeichnet sich durch eine weitgehend natürliche Belüftung ohne Klimatisierung aus – eine Seltenheit im Bereich des Hochhausbaus. Ermöglicht wird dies durch eine massive Gebäudestruktur mit einer hohen thermischen Speicherfähigkeit und einer Fassadenstruktur zur Reduzierung der solaren Gewinne im Sommer. Nur die Hörsäle mit einer Kapazität zwischen 60 und 800 Plätzen, sowie kleinere Sonderbereiche verfügen über eine mechanische Lüftungsanlage. Die Wärmeversorgung des Gebäudes erfolgt über ein im Quartier vorhandenes Nahwärmenetz.



Abbildung 28: Außenansicht (links) und Innenansicht eines Hörsaals (rechts) für das Maison du Savoir der Universität Luxembourg. [Bildquelle: Universität Luxembourg, 12.12.2024].

### 4.2.1. Lüftungskonzept und -technik

Die Hörsäle werden über dezentral in unmittelbarer Nähe angeordnete RLT-Anlagen mit Frischluft sowie Wärme und Kälte zur Raumluftkonditionierung versorgt. Zusätzliche Systeme zum Heizen oder Kühlen sind nicht installiert. Die Dimensionierung der in Tabelle 14 aufgeführten Nennvolumenströme für die von der Firma Robatherm hergestellten Anlagen erfolgte auf Basis der maximalen Belegungszahl. Ansonsten sind die Anlagenkonfigurationen, bestehend aus einem Wärmerückgewinnungsrad, Luftfilter, Heizregister und einer adiabaten Kühlung, für alle Anlagen identisch. Ein Prinzipschema für die observierten Lüftungsanlagen zeigt Abbildung 29.

*Tabelle 14: Nennvolumenströme und Luftbehandlungsfunktionen der RLT-Anlagen im Maison du Savoir.*

Akronym	Zone	$\dot{V}_{Teillast}$ <i>m³/h</i>	$\dot{V}_{Volllast}$ <i>m³/h</i>	Luftbehandlungs- funktionen*			
				H	K	F	WRG
<b>AUD2</b>	Auditorium 2	3150	5250	✓	✓	✓	O
<b>AUD4</b>	Auditorium 4	1890	3150	✓	✓	✓	O
<b>AUD7</b>	Auditorium 7	5040	8400	✓	✓	✓	O
<b>AUD8</b>	Auditorium 8	1890	3150	✓	✓	✓	O
<b>AUD9</b>	Auditorium 9	5040	8400	✓	✓	✓	O
<b>AUD11</b>	Auditorium 11	3150	5250	✓	✓	✓	O

\* H: Heizen, K: Kühlen, F: Filtern, WRG: Wärmerückgewinnung (X = Kreuzstromwärmetauscher, O = Rotationswärmetauscher)

Die Regelstrategie der RLT-Anlagen im MSA ist nicht schriftlich dokumentiert. Für die Interpretation der Betriebsdaten war es daher notwendig die Regelstrategien anhand der Messdaten und aus Gesprächen mit dem betreuenden Fachpersonal abzuleiten. Folgende wesentliche Eigenschaften lassen sich formulieren:

- Die Zulufttemperatur wird in Abhängigkeit der Raumluft geregelt, wobei die maximale Temperatur 30°C nicht überschreitet. Abhängig von der Versorgungszone und dem Betrachtungszeitraum liegt der Sollwert für die Raumlufttemperatur im Heizbetrieb zwischen 21°C und 22°C. Im Kühlbetrieb erhöht sich der Sollwert meist um 2 K. Für einzelne Anlagen konnten anfangs jedoch abweichende Vorgaben identifiziert werden, die im Rahmen des technischen Monitorings korrigiert wurden.
- Die Außen- und Umluftklappen des Systems werden über ein gemeinsames Signal angesteuert, sodass mit erhöhtem Umluftanteil die Außenluftklappen anteilig

#### 4. Beschreibung der Fallstudien

schließen. Bei aktivierter adiabater Kühlung ist kein Umluftbetrieb möglich. Zudem wurde der Umluftbetrieb im Betrachtungszeitraum aufgrund der COVID-Pandemie temporär unterbunden.

- Für die Luftvolumenströme sollte nach Aussage eines Technikers eine CO<sub>2</sub> geführte Stufenregelung aktiv sein (Stufe 1 = 60% des Nennvolumenstroms bis 1000 ppm, Stufe 2 = linearer Anstieg des Volumenstroms bis zum Nennvolumenstrom bei 1500 ppm). Anhand der Messdaten können die Regelstrategie jedoch nicht eindeutig bestätigt und zum Teil von Anlage zu Anlage unterschiedliche Verhalten beobachtet werden.




Abbildung 29: Anlagenschema mit einer standardisierten Kennzeichnung der erfassten Datenpunkte für die mechanische Lüftungsanlage der Hörsäle im Maison du Savoir (MSA).

Allgemein lässt sich für die RLT-Anlagen des MSA-Gebäudes feststellen, dass die implementierte Regelstrategie komplex und auch für einen Experten anhand der Betriebsdaten schwierig zu rekonstruieren ist. Erschwert wird dies insbesondere durch eine Vielzahl grenzwertbasierter vom Normalbetrieb abweichende Funktionen, wie z.B. für den Frostschutz oder das Einschalten einer Komponente (Pumpen) nach dem Erreichen einer maximalen Stillstandsdauer. Am Beispiel des MSA-Gebäudes wird deutlich, dass eine Überprüfung von Soll- und Ist-Betrieb im Rahmen eines technischen Monitorings oder eine physikalische Modellierung des Gesamtsystems ohne eine ausführliche Dokumentation der implementierten Regelstrategie nicht möglich ist. Dies stellt auch für die Implementierung eines FED-Prozesses eine besondere Herausforderung in der Praxis dar.



Abbildung 30: Ansicht einer RLT-Anlage im Maison du Savoir (links) und Detailfoto vom hydraulischen Anschluss des Heizregisters.

### 4.2.2. Datengrundlage

In einer Zusammenarbeit der Universität Luxemburg mit dem Gebäudebetreiber Le Fonds-Belval werden die Betriebsdaten von sechs Lüftungsanlagen als sogenannte Offlinetrends aufgezeichnet und auf einem Datenserver gespeichert. Anhand der Betriebsdaten wird ein kontinuierliches technisches Monitoring durchgeführt. Gleichzeitig sollen die Daten für die angewandte Forschung nutzbar gemacht werden. Folgende Datenpunkte werden im Rahmen des Monitorings für die observierten RLT-Anlage erfasst (vgl. Abbildung 29):

- Betriebsstatus
- Stellsignal der Klappen für Fortluft, Frischluft und Umluft (ein gemeinsames Signal)
- Steuersignale für Zu-, Abluftventilator und Rotationswärmetauscher
- Fehlermeldungen der Luftfilter
- Raumsolltemperatur für den Heiz- und Kühlbetrieb (Winter/Sommer)
- Temperatur und relative Feuchte an unterschiedlichen Positionen in der Zu- und Abluft
- Temperatur der Raumluft
- Luftqualität der Ab- und Raumluft
- Ventilstellung, Rücklauftemperatur und Pumpenstatus im Wasserkreislauf des Heizregisters
- Ventilstellung und Pumpenstatus im Wasserkreislauf der adiabaten Kühlung
- Thermische und elektrische Energieverbräuche für die RLT-Anlagen AUD2 und AUD7

Die Speicherung erfolgt für einen Großteil der Daten in einem konstanten Intervall von 5 Minuten. Bei einigen Datenpunkten (z.B. Alarme der Filter) handelt es sich um so-

#### 4. Beschreibung der Fallstudien

---

nannte Eventdaten, die systembedingt nur bei einer Zustandsänderung ausgegeben werden. Zudem werden einzelne Datenpunkte (z.B. Außenlufttemperatur) in einem größeren Intervall gespeichert. Eine detaillierte Auflistung der Datenpunkte mit einer Kurzbeschreibung, Datenpunktbezeichnung, Einheit und Logintervall befindet sich in Anhang A6 (Tabelle 30). Die Datenverfügbarkeit beschränkt sich auf den Zeitraum vom 18.05.2021 bis einschließlich 29.07.2023. Eine Ausnahme bilden die CO<sub>2</sub>-Konzentrationen der Raum- und Abluft mit einem späteren Messbeginn am 22.04.2022. Im Rahmen einer Kooperation des Fond Belval mit einem externen Dienstleister zur Verbesserung der Energieeffizienz hat sich die Regelstrategie und damit das Betriebsverhalten im Oktober 2022 charakteristisch verändert. Eine veränderte Regelstrategie im laufenden Betrieb erfordert jedoch erneutes Training der eingesetzten ML-Modelle. Vor diesem Hintergrund werden in dieser Arbeit folgende Zeiträume definiert:

- Trainingszeitraum: 19.05.2021 bis 18.01.2022 (7 Monate)
- Validierungszeitraum: 19.01.2022 bis 18.07.2022 (6 Monate)
- Testzeitraum: 19.07.2022 bis 18.10.2022 (3 Monate)

Die in den Datensätzen enthaltenen Betriebsmodi und deren prozentuale Anteile repräsentativ die Abbildung 31 (AUD8) und Abbildung 32 (AUD9). Weitere Diagramme für die übrigen RLT-Anlagen im MSA-Gebäude befinden sich in Anhang A7. Der Betrieb der RLT-Anlage AUD8 wird wesentlich durch die Modi Frischluft (47%, Testzeitraum) und Heizen (51%, Testzeitraum) geprägt. Aufgrund der langen Schließzeiten des Gebäudes in den Sommermonaten ist der Anteil der Kühlung mit 1,4% im Testzeitraum sehr gering. Im Validierungs- (4%) und Testzeitraum (8%) steigt der Anteil leicht, gleichzeitig kann der Heizbetrieb seltener beobachtet werden (38%, Testzeitraum). Ein Umluftbetrieb findet nicht statt. Deutlich anders sind die Betriebsmodi in den Datensätzen der RLT-Anlage AUD9 verteilt. In dem Trainings- (64%) sowie dem Testdatensatz (74%) dominieren der Frischluftbetrieb, während der Anteil im Validierungszeitraum deutlich niedriger liegt (39%). Gleichzeitig ist hier ein deutlich höherer Anteil im Heizbetrieb (50%) zu beobachten. Anders als für die Anlage AUD8, wird die Anlage AUD9 im Trainings- (11%) und Validierungszeitraum (5%) deutlich häufiger im Umluftmodus betrieben, welcher im Testzeitraum nicht mehr vertreten ist. Dafür steigt der Anteil im Kühlbetrieb deutlich auf 19%. Aufgrund des kurzen Testzeitraumes (3 Monate) der sich über eine Jahreszeit mit höheren Außenlufttemperaturen erstreckt, kann bei allen Anlagen im Testzeitraum ein tendenziell geringerer Anteil im Heizbetrieb und ein häufige-

rer Kühlbetrieb beobachtet werden. Dennoch unterscheiden sich die Anteile von Anlage zu Anlage trotz gleicher Nutzungsart deutlich.




Abbildung 31: Anteile der Betriebsmodi für die RLT-Anlage AUD8 im MSA-Gebäude an den Datensätzen für das Training, die Validierung und das Testen.




Abbildung 32: Anteile der Betriebsmodi für die RLT-Anlage AUD9 im MSA-Gebäude an den Datensätzen für das Training, die Validierung und das Testen.

#### 4.2.3. Synthetischer Datensatz

Synthetische Datensätze haben den Vorteil, dass der wahre Fehlerzustand des Systems bekannt ist (siehe Abschnitt 3.6) und eignen sich daher gut für die Entwicklungs- und frühe Testphase von FED-Systeme. Vor diesem Hintergrund wird ergänzend zu den messtechnisch erfassten Betriebsdaten ein mit Hilfe der Simulationsumgebung TRNSYS (Version 18) [59] synthetisch generierter Datensatz angewendet. Die Parametrisierung der Modell-Komponenten erfolgt auf Grundlage der technischen Dokumentation für die RLT-Anlage AUD8, wobei die implementierten Regelstrategie aufgrund einer fehlenden Beschreibung anhand des observierten Regelverhaltens abgeleitet wird.

#### 4. Beschreibung der Fallstudien

TRNSYS ermöglicht eine dynamische Simulation basierend auf physikalischen Systemgleichungen. Abbildung 33 zeigt die umgesetzte Modellstruktur mit den modellierten Komponenten des technischen Systems und die verwendeten Modelltypen – sogenannte Types – aus der TRNSYS Modellbibliothek. Eine mathematische Beschreibung der Modelle kann der Dokumentation [60] entnommen werden. Das Gesamtmodell ermöglicht die Bilanzierung der Massen- und Energieströme inklusive der Druckverhältnisse im Zu- und Abluftstrang sowie im hydraulischen Kreislauf Heizregisters. Nicht berücksichtigt ist hingegen die adiabate Kühlfunktion. Die Wechselwirkung mit der versorgten Gebäudezone wird mit einem einfachen kapazitiven Einzonen-Modell abgebildet, welches die Einflüsse der Gebäudemasse, der interne Gewinne und der thermischen Verluste über die Gebäudehülle durch einen globalen U-Wert einbezieht, jedoch solare Gewinne vernachlässigt.




Abbildung 33: Schematische Darstellung des in der Programmumgebung TRNSYS umgesetzten dynamischen Simulationsmodells für die RLT-Anlage AUD8 im MSA-Gebäude.

Um den Einfluss sich ändernder klimatischer Randbedingungen zu berücksichtigen, werden zwei verschiedene Wetterdatensätze von den Standorten Saarbrücken und Trier für die Durchführung jährlicher Simulationen verwendet. Neben dem fehlerfreien Betrieb werden auch drei verschiedenen Fehlerzustände mit zufälligem Zeitpunkt sowie Fehlergröße implementiert und in den fünfminütigen Ausgangsdaten gelabelt. Hierzu gehören

- ein feststehendes Regelventil im hydraulischen Kreislauf des Heizregisters
- eine Fehlfunktion des Rotors für die Wärmerückgewinnung
- und ein Sensorfehler für die Ablufttemperatur.

Eine direkte Modellierung von Prozessfehlern ist mit den vorhandenen Modelltypen in der TRNSYS-Software Umgebung nicht möglich, da die Modellparameter und Gleichungen nicht während der Laufzeit verändert werden können. Aus diesem Grund wird das fehlerhafte Verhalten indirekt über eine Manipulation der Stellsignale und Messwerte während der Simulation herbeigeführt. Insgesamt umfasst der Datensatz einen Zeitraum



von zwei Jahren mit fehlerfreiem Betrieb und weitere zwei Jahre mit Fehlerzuständen. Um zu verhindern, dass die Fehler sich gegenseitig beeinflussen, befindet sich zwischen den Fehlerevents eine Pause von mindestens 3 Tagen. Der fehlerfreie Zeitraum wird wie folgt für das Trainieren der FED-Methodik aufgeteilt.

- Trainingszeitraum: 01.01. bis 31.12. (1 Jahr, fehlerfrei)
- Validierungszeitraum: 01.01. bis 30.06. (6 Monate, fehlerfrei)
- Fehlerfreier Testzeitraum: 01.07. – 31.12. (6 Monate)
- Fehlerbehafteter Testzeitraum: 01.01 (Jahr 1) – 31.12. (Jahr 2) (24 Monate)

### 4.3. Anonymisierte Liegenschaft

In Kooperation mit der auf Gebäudetechnik spezialisierten Fachfirma a+p kieffer omnitec wurden der Betrieb von Lüftungsanlagen einer anonymisierten Liegenschaft (Akronym: ISC) in Luxemburg analysiert. A+p kieffer omnitec zeichnet sich verantwortlich für die Installation der technischen Gebäudeausrüstung sowie die Wartungsarbeiten im Rahmen eines Contracting-Modells. Der Austausch hinsichtlich der Erfahrungen im Bereich des Facility Managements, auch aus anderen Liegenschaften, lieferte einen wesentlichen Beitrag hinsichtlich der Anforderungen in der praktischen Anwendung von FED-Methoden und damit der Zielstellung dieser Arbeit (siehe Abschnitt 1.1). Das energetische Konzept ist geprägt durch

- eine hohe Qualität der thermischen Gebäudehülle, die einen Energieverbrauch im Niedrigenergiestandard (30 kWh/m<sup>2</sup> Jahr) ermöglicht,
- eine möglichst gute Nutzung von Tageslicht sowie eine tageslichtabhängige Regelung der Beleuchtung,
- ein passives Kühlkonzept über eine natürliche Nachtauskühlung kombiniert mit einer hohen thermischen Masse der Gebäudestruktur,
- eine hybride natürliche und mechanische Lüftung während den Nutzungszeiten zur Minimierung des elektrischen Energieeinsatzes,
- und einen großen Anteil regenerativer Energien (Holzkessel, Geothermie und solarthermische Kollektoren) an der Wärmeerzeugung.

## 4. Beschreibung der Fallstudien

### 4.3.1. Lüftungskonzept und -technik

Die RLT-Anlagen im Gebäude versorgen einheitlich genutzte Zonen innerhalb des Gebäudes, wobei sich der Volumenstrom am Frischluftbedarf der jeweiligen Zone orientiert. Alle Anlagen verfügen über eine WRG (Kreuzstrom- oder Rotationswärmetauscher), wodurch auch im Winter die Sanitärbereiche ohne Nacherhitzung versorgt werden können. In den übrigen Bereichen wird die Zuluft auf eine Mindesttemperatur vorerhitzt und raumseitig durch ein statisches Heizsystem auf die Raumsolltemperatur gebracht. Eine Ausnahme bilden die RLT-Anlagen zur Versorgung eines Theatersaals und eines Sportbereiches, die zusätzlich einen Umluftbetrieb ermöglichen, um die notwendige Raumwärme einzubringen. Insgesamt sind 15 RLT-Anlagen im Gebäude installiert, von denen in dieser Arbeit 5 Anlagen betrachtet werden. Die Nennvolumenströme, Versorgungszonen und Luftbehandlungsfunktionen sind in Tabelle 15 aufgeführt. Abbildung 34 zeigt exemplarisch das Anlagenschema für die Lüftungsanlage zur Versorgung des Theatersaals.




Abbildung 34: Anlagenschema mit einer standardisierten Kennzeichnung der erfassten Datenpunkte für die Lüftungsanlage des Theatersaals (CTA02) in der anonymisierten Liegenschaft (ISC).

*Tabelle 15: Nennvolumenströme und Luftbehandlungsfunktionen der RLT-Anlagen im ISC-Gebäude.*

Akronym	Zone	$\dot{V}_{Teillast}$	$\dot{V}_{Volllast}$	Luftbehandlungsfunktionen*			
				$m^3/h$	$m^3/h$	H	K
CTA01	Sanitärbereich 1	-	800	-	-	✓	X
CTA02	Theatersaal	2400	6000	✓	-	✓	O
CTA03	Sanitärbereich 2	600	1200	-	-	✓	X
CTA08	Fachräume (Labore)	900	3000	✓	-	✓	X
CTA17	Wohnbereich	2200	5000	✓	-	✓	O

\* H: Heizen, K: Kühlen, F: Filtern, WRG: Wärmerückgewinnung (X = Kreuzstromwärmetauscher, O = Rotationswärmetauscher)

### 4.3.2. Datengrundlage

Die Firma a+p kieffer omnitec hat einen umfassenden Datensatz über einen Zeitraum von 10 Jahren bereitgestellt, wobei der Fokus, der im Rahmen der Kooperation durchgeführten Analyse des Betriebsverhaltens, auf dem rezenten Zeitraum von 2017 bis 2022 lag. Für die Entwicklung der FED-Methodik werden aus dem Datensatz folgende Zeiträume definiert:

- Trainingszeitraum: 01.01.2017 bis 31.12.2017 (12 Monate)
- Validierungszeitraum: 01.01.2018 bis 31.12.2018 (12 Monate)
- Testzeitraum: 01.01.2019 bis 31.12.2019 (12 Monate)

Im Gegensatz zu den anderen Fallstudien werden die Betriebsdaten in einem größeren Zeitintervall erfasst. Abhängig vom Datenpunkt erfolgt die Aufzeichnung eventbasiert oder in einem 15, 20, bzw. 30-minütigem Intervall. Hierdurch ergibt sich eine sehr heterogene Datenbasis, die ein sorgfältiges Vorverarbeiten für eine Analyse der Zeitreihendaten erfordert. Eine detaillierte Datenpunktliste mit Kurzbeschreibung, Logintervall und Verfügbarkeit je RLT-Anlage befindet sich in Anhang A9 (Tabelle 31). Zusammenfassend werden folgende Zustands- und Stellgrößen der Systeme erfasst:

- Betriebsstatus
- Stellsignal der Klappen für Fortluft, Frischluft und Umluft
- Steuersignale für Zu-, Abluftventilator und Rotationswärmetauscher, bzw. Bypass des Kreuzstromwärmetauschers
- Volumenströme der Zu- und Abluft

#### 4. Beschreibung der Fallstudien

- Förderdruck der Ventilatoren und für CTA07 sowie CTA17 zusätzliche Kanaldrücke
- Sollwerte für die Zulufttemperatur, Drücke und Volumenströme im System
- Außen-, Fort-, Ab- und Zulufttemperatur (im Luftkanal)
- Luftqualität der Abluft (nur Theatersaal)
- Ventilstellung, Rücklauftemperatur und Pumpenstatus im Wasserkreislauf des Heizregisters
- Thermischen Energieverbrauch bei vorhandenem Heizregister

Die Betriebscharakteristiken der RLT-Anlagen im ISC-Gebäude können anhand der Daten allgemein als sehr konstant mit wenig transienten Zuständen, keinen Änderungen von Regler-Einstellungen und gleichbleibender Nutzung der Zonen im Betrachtungszeitraum eingestuft werden. Dies führt für alle Anlagen zu einer nahezu identischen Verteilung der möglichen Betriebsmodi in den Datensätzen für das Training, die Validierung und das Testen. Exemplarisch sind in den Abbildung 35 und Abbildung 36 die Verteilungen für die Lüftungsanlagen CTA02 und CTA17 dargestellt. Die Anteile der Betriebsmodi an den Betrachtungszeiträumen für die übrigen Anlagen im ISC-Gebäude sind in Anhang A10 dargestellt. Die RLT-Anlage CTA02 zur Versorgung eines Theatersaals wird vorrangig im Frischluftbetrieb mit modulierender Rotorgeschwindigkeit der Wärmerückgewinnung betrieben (ca. 70%). Zudem lässt sich, im Unterschied zu den anderen Anlagen der untersuchten Fallstudien, ein hoher Anteil im Umluftbetrieb (ca. 26%) zur Versorgung der Zone mit Raumwärme feststellen. Anlage CTA8 (Fach- und Laborräume) wird hingegen ausgewogen im Heiz- und Frischluftmodus mit optionalem Bypass für die WRG betrieben.




Abbildung 35: Anteile der Betriebsmodi für die RLT-Anlage CTA02 im ISC-Gebäude an den Datensätzen für das Training, die Validierung und das Testen.

## 4. Beschreibung der Fallstudien




Abbildung 36: Anteile der Betriebsmodi für die RLT-Anlage CTA08 im ISC-Gebäude an den Datensätzen für das Training, die Validierung und das Testen.

## 4. Beschreibung der Fallstudien

---

### 5. Darstellung und Analyse der Ergebnisse

Der in Kapitel 3 vorgestellte Entwurf für einen Residuen-generierenden FED-Ansatz unter Einbindung von ML-Methoden wird systematisch auf insgesamt 17 Datensätze aus dem Betrieb von RLT-Anlagen in drei unterschiedlichen Gebäuden angewendet. In diesem Kapitel werden die erzielten Ergebnisse dargestellt und hinsichtlich

- der Schätzqualität für das nominale Betriebsverhalten (Abschnitt 5.1),
- der Performance der Residuen-Evaluierung mit anschließender Fehlererkennung (Abschnitt 5.2),
- und der Fähigkeit zur Fehlerisolation auf Basis der Residuen-Muster (Abschnitt 5.3) ausgewertet.

#### 5.1. Qualität der Schätzung für das nominale Betriebsverhalten

Im Residuen-generierenden FED-Ansatz wird die Performance des Gesamtprozesses wesentlich durch die Schätzungsgüte des nominalen Verhaltens beeinflusst. Größere Modellunsicherheiten verringern die Signifikanz der Residuen und damit die Sensitivität der FED. Die Eignung eines ML-Algorithmus hängt vor allem von den Eigenschaften der Betriebsdaten, wie Datenqualität, Datenverteilung und zeitlichem Verhalten, ab. Dies erfordert eine sorgfältige Modellauswahl. In Abschnitt 5.1.1 wird die Performance unterschiedlicher Modellansätze für den Einsatz mit Betriebsdaten aus RLT-Anlagen untersucht. Die Ergebnisse bilden die Grundlage für das Verfahren zur Modellierung des nominalen Betriebsverhaltens im vorgestellten FED-Entwurf (Abschnitt 3.3.2), dessen Performance in den Abschnitten 5.1.2 bis 5.1.4 anhand der Fallstudien analysiert wird.

Die Methodik wird ohne eine individuelle Anpassung der Parameter auf die Datensätze angewendet, wodurch auch Aussagen zur Übertragbarkeit möglich sind. Zunächst werden die Schätzfehler für die einzelnen Systemgrößen sowie die durchschnittlichen Fehler pro RLT-Anlage analysiert. Anschließend wird anhand von Zeitreihenbeispielen die Performance veranschaulicht und die Ursachen für Abweichungen zwischen den Schätzungen und den beobachteten Daten untersucht. Die hierbei gewonnenen Erkenntnisse sind eine wichtige Grundlage für die Interpretation der Ergebnisse in der nachfolgenden Fehlererkennung und -isolation.

Darüber hinaus werden Einflussfaktoren, wie fehlerhafte Betriebszustände in den Trainingsdaten (Abschnitt 5.1.5.1) und die Länge des Trainingszeitraumes (Abschnitt 5.1.5.2), auf die Schätzqualität näher analysiert. Abschließend werden die Ergebnisse

## 5. Darstellung und Analyse der Ergebnisse

---

zur Schätzung des nominalen Betriebsverhaltens zusammengefasst und Empfehlungen für die praktische Anwendung formuliert (Abschnitt 5.1.6).

### 5.1.1. Voruntersuchungen zur Performance unterschiedlicher ML-Ansätzen

Die grundsätzliche Eignung unterschiedlicher ML-Ansätze aus dem Bereich des überwachten Lernens wird anhand der Zulufttemperatur für die RLT Anlage FLA der Grundschule Hohen Neuendorf (GSHN) untersucht. Dazu erfolgt die Aufbereitung der Eingangsdaten nach dem in Abschnitt 3.3.1 beschriebenen Verfahren, wobei ein Gesamtzeitraum von zwei Jahren anteilig für das Modelltraining (40%), das Validieren (10%) und das Testen (50%) genutzt wird. Mit dem Ziel, die notwendige Rechenkapazität und die Datenmenge für das Training gering zu halten, werden hauptsächlich ML-Ansätze mit geringer Komplexität eingesetzt. Dies ist notwendig, da im verfolgten FED-Ansatz das nominale Verhalten mit separaten Modellen je Schätzgröße abgebildet wird.

In Tabelle 16 sind die für die Regressionsaufgabe untersuchten Modellansätze sowie die evaluierten Metriken (MAE<sup>16</sup>, MSE<sup>17</sup>, RMSE<sup>18</sup>) für den Trainings- und Validierungszeitraum aufgelistet. Eine grundlegende Beschreibung der angewendeten ML-Methoden findet sich in Tabelle 2, Abschnitt 2.4. Alle dargestellten Metriken zeigen eine vergleichbare Tendenz hinsichtlich der erzielten Schätzqualität. Ein wesentlicher Unterschied liegt in der Bewertung des Fehlers. Während beim MAE die Differenzen zwischen Schätzung und Messwert gleich stark berücksichtigt werden, fließen bei den Metriken MSE und RMSE größere Abweichungen quadratisch ein (siehe Anhang A1). Sie sind daher anfälliger gegenüber Ausreißer. Aufgrund der besseren Interpretierbarkeit wird in dieser Arbeit der MAE zur Darstellung der Ergebnisse herangezogen.

*Tabelle 16: Metriken für unterschiedliche Modellansätze zur Schätzung der Zulufttemperatur. Die Berechnung der Metriken erfolgte auf Basis des Trainings- und Validierungszeitraumes.*

<b>Model</b>	<b>MAE</b> in K	<b>MSE</b> in K <sup>2</sup>	<b>RMSE</b> in K
Light Gradient Boosting Machine	0,33	0,23	0,46
Extra Trees Regressor	0,34	0,26	0,48
Random Forest Regressor	0,35	0,27	0,49
Gradient Boosting Regressor	0,37	0,27	0,50
Decision Tree Regressor	0,43	0,40	0,60

---

<sup>16</sup> Mittlerer absoluter Fehler (engl.: Mean Absolute Error, kurz: MAE)

<sup>17</sup> Mittlerer quadratischer Fehler (engl. Mean Squared Error, kurz MSE)

<sup>18</sup> Wurzel des mittleren quadratischen Fehlers (engl. Root Mean Squared Error, kurz RMSE)



## 5. Darstellung und Analyse der Ergebnisse

<b>Model</b>	<b>MAE</b> in K	<b>MSE</b> in K <sup>2</sup>	<b>RMSE</b> in K
AdaBoost Regressor	0,48	0,41	0,62
K Neighbors Regressor	0,69	0,85	0,91
Support Vector Regression	0,73	0,88	0,92
Elastic Net	0,81	1,03	1,01
Lasso Regression	0,82	1,00	1,00
Ridge Regression	0,89	2,45	1,48
Bayesian Ridge	0,89	2,41	1,47
Linear Regression	0,90	2,41	1,47
Orthogonal Matching Pursuit	1,00	2,88	1,63
Passive Aggressive Regressor	1,02	1,95	1,36
Lasso Least Angle Regression	1,25	2,13	1,45
Automatic Relevance Determination	1,32	3,08	1,73
Random Sample Consensus	1,80	8,75	2,80
TheilSen Regressor	2,29	638,11	18,69
Huber Regressor	3,60	20,38	4,44
Kernel Ridge	6,56	124,60	9,89
Least Angle Regression	14,47	508,07	21,11

Für eine Eignungsbewertung lässt sich keine feste Wertgrenze für den MAE definieren. Dieser hängt wesentlich vom Wertebereich der observierten Größe ab. Gleichzeitig muss neben der Auswertung globaler Metriken auch das zeitliche Verhalten analysiert werden. Die Zulufttemperatur von RLT-Anlagen liegt üblicherweise in einem engen Wertebereich zwischen 18°C und 30°C, sodass ein MAE größer 1,0 K als unzureichend eingestuft werden kann, während Fehlerbeträge kleiner 0,5 K bereits im Bereich der Messunsicherheit liegen. Anhand der Ergebnisse wird deutlich, dass ein Großteil der untersuchten Algorithmen MAE-Werte größer 0,7 K aufweisen, während die gut performenden Modelltypen MAEs kleiner 0,4 K erreichen. Exemplarisch ist in Abbildung 38 (Mitte) der Tagesverlauf für eine Schätzung mit dem Modelltyp *Support Vector Regression* abgebildet. Es wird deutlich, dass das Modell Schwierigkeiten hat, die dynamischen Vorgänge in der Zulufttemperatur aufgrund des alternierenden Regelverhaltens des Heizregisterventils am dargestellten Wintertag zu schätzen.

## 5. Darstellung und Analyse der Ergebnisse

---

Deutlich bessere Ergebnisse erzielen Regressionsmethoden aus der Familie der Entscheidungsbäume, bzw. Methoden, die mehrere Entscheidungsbäume kombinieren (*Random Forest*) ( $MAE \leq 0,35$ ). Insbesondere in dynamischen Bereichen werden höhere Genauigkeiten erreicht, wobei der Algorithmus *Light Gradient Boosting Machine* am besten performt. Tabelle 17 zeigt für diesen Modelltyp zusätzlich die Metriken für den Testdatensatz. Im Vergleich zum Trainings- und Validierungszeitraum steigt der MAE von 0,33 K auf 0,55 K, bleibt absolut betrachtet aber auf einem niedrigen Niveau. Exemplarische Tagesverläufe für den Winter- und Sommerbetrieb zeigt Abbildung 38 (links). Während im Winterbetrieb nur temporär Abweichungen zwischen Schätzung und Observation vorhanden sind, ist im Sommerbetrieb ein kontinuierlicher Offset von ca. 1 K zu beobachten.

Ergänzend wird der Einsatz von zwei unterschiedlichen Typen neuronaler Netze (NN) für die Modellierung des Systemverhaltens untersucht: Multilayer-Perceptron (MLP) und Long-Short-Term-Memory Networks (LSTM) (siehe Abschnitt 2.4). Die hier durchgeführten Voruntersuchen adressieren die notwendige Modellkapazität und den Einfluss der gewählten Architektur für den gegebenen Anwendungsfall. Folgende Hyperparameter werden in den aufgeführten Grenzen variiert:

- die Anzahl der Neuronen je Schicht über einen Skalierungsfaktor (0.5, 1.0, 1.5, 2.0)
- die Anzahl der Hidden-Layers (1-9)
- und die verwendete Aktivierungsfunktion (Sigmoid, ReLu, Tanh).

Die untersuchten LSTM-NN erzielen im Vergleich zu den MLP-NN ähnliche Ergebnisse. Für beide Modelltypen liegt der kleinste Fehler mit einem MAE von ca. 0,3 K auf einem niedrigen Niveau (siehe Tabelle 17). Allerdings benötigen LSTM-NN aufgrund ihrer komplexeren Modellstruktur deutlich längere Rechenzeiten für das Training. Im Hinblick auf die Genauigkeit und Konvergenz des Lösungsverfahrens erweisen sich MLP-NN mit ReLU- oder Sigmoid-Aktivierungsfunktion als am robustesten. Die Ergebnisse der Kapazitätsanalyse für den Testdatensatz dieses Modelltyps sind in Abbildung 38 dargestellt. Eine entsprechende Darstellung der Ergebnisse für die untersuchten LSTM-NN befindet sich in Anhang A12 (Abbildung 95).

## 5. Darstellung und Analyse der Ergebnisse




Abbildung 37: Metriken (MAE, RMSE) für unterschiedliche Modellkapazitäten eines Multi-Layer-Perceptron (MLP) Models mit ReLU-Aktivierungsfunktion zur Schätzung der Zulufttemperatur (GSHN, RLT-Anlage FLA).

Aus den Diagrammen wird deutlich, dass eine höhere Modellkapazität nicht zwangsläufig zu einer besseren Modellqualität (MAE) führt. Durch Überanpassung komplexerer Modelle an den Trainingsdatensatz besteht die Gefahr, dass die generalisierenden Eigenschaften des Modells abnehmen (z. B. bei 9 Schichten und einem Neuronenfaktor von 0,5). Für die Anwendung in einem Residuen-generierenden Prozess müssen daher die geeigneten Modellkomplexitäten individuell für den jeweiligen Datensatz und die Zielgrößen der Schätzung mithilfe eines Optimierungsverfahrens bestimmt werden. In den hier untersuchten Varianten liefert das Modell mit sechs Schichten und einem Neuronenfaktor von 0,5 die beste Schätzqualität. Im Vergleich zum Modelltyp *Light Gradient Boosting Machine* kann durch den Einsatz von MLP- oder LSTM-Netzwerken der MAE-Wert für den Testdatensatz von 0,55 K auf 0,33 K gesenkt werden (siehe Tabelle 17).

Tabelle 17: Ergebnisse für den Modelltyp „Light Gradient Boosting Machine“ bei einer Schätzung basierend auf dem Testdatensatz.

Model	MAE in K	MSE in K <sup>2</sup>	RMSE in K
Light Gradient Boosting Machine	0,55	0,50	0,71
Long-Short-Term-Memory Networks (LSTM) (2 Schichten, Faktor für Neuronen: 1,5, ReLu-Aktivierungsfunktion)	0,33	0,23	0,47
Multi-Layer-Perceptron (6 Schichten, Faktor für Neuronen: 0,5, ReLu-Aktivierungsfunktion)	0,32	0,23	0,47

## 5. Darstellung und Analyse der Ergebnisse




Abbildung 38: Schätzungen der Zulufttemperatur (GSHN, FLA) durch unterschiedliche Modellansätze für einen Sommer- (oben) und einen Wintertag (unten).

Abbildung 38 zeigt die Schätzergebnisse verschiedener Modelltypen anhand ausgewählter Zeitreihen für einen Sommertag (oben) und einen Wintertag (unten). Im Gegensatz zum Modelltyp *Support Vector Regression* können sowohl das MLP-NN als auch der Modelltyp *Light Gradient Boosting Machine* die Heizvorgänge im Winterzeitraum mit einem dynamischen Verlauf der Zulufttemperatur gut abbilden. Im dargestellten Sommerfall zeigt das MLP-NN hingegen eine deutlich bessere Übereinstimmung mit den Messwerten. Insgesamt lässt sich eine gute Eignung des MLP-Netzwerks zur Schätzung des nominalen Verhaltens im Residuen-generierenden FED-Ansatz feststellen. Insbesondere im Vergleich zu den in Tabelle 16 betrachteten Algorithmen bildet das MLP-Netzwerk die Gesamtheit der Betriebszustände deutlich besser ab. Gegenüber den untersuchten LSTM-NN reduziert der Einsatz von MLP-NN die erforderliche Rechenleistung bei vergleichbarer Schätzqualität.

### 5.1.2. Grundschule Hohen Neuendorf

In der Fallstudie der Grundschule Hohen Neuendorf (GSHN) können aufgrund der umfangreichen Datenverfügbarkeit jeweils Zeiträume von einem Jahr für das Training und die Validierung der Modelle sowie für die Bewertung der Ergebnisse in der Anwendungsphase (Testen) genutzt werden. Die Schätzung erfolgt dabei individuell für jede

Variable auf Basis der in Abschnitt 3.3 vorgestellten Methodik unter Anwendung von Multilayer-Perceptron (MLP) Netzwerken.

Abbildung 39 zeigt den normalisierten mittleren absoluten Fehler (nMAE) sowie dessen Median für die Schätzungen der observierten Variablen der RLT-Anlagen im Testzeitraum. Um eine einheitliche Darstellung und einen Vergleich der Ergebnisse zu ermöglichen, wird eine Normalisierung relativ zum Wertebereich der jeweiligen Variablen während des Testzeitraums vorgenommen. Damit Ausreißer die Ergebnisse nicht übermäßig beeinflussen, definieren das untere und obere Perzentil bei 0,5 % bzw. 99,5 % die Grenzen des Wertebereiches. Systemgrößen wie Stellsignale, die bereits in den Rohdaten in einem Wertebereich zwischen 0 und 1 liegen, werden nicht normalisiert. Für alle Anlagen der GSHN sind dieselben Systemgrößen in den Datensätzen enthalten. Eine Ausnahme bildet die RLT-Anlage der Aula (AUL), die zusätzlich über eine adiabaten Kühlfunktion verfügt. Hier werden ergänzend die relativen Luftfeuchten der Zu-, Ab- und Außenluft erfasst. Nicht dargestellt sind die Ergebnisse für diskrete Variablen, deren Schätzgüte durch den F1-Score bewertet werden. Für die GSHN handelt es sich hierbei um die Stellsignale für den Umluftbetrieb ( $U_{Umluft}$ ) und die Pumpe der adiabaten Kühlung ( $U_{ADK,Pu}$ ) aus dem Betrieb der RLT-Anlage AUL. Für diese Größen indizieren F1-Scores<sup>19</sup> von 99,3% und 97,8% eine gute Schätzung.




Abbildung 39: Normalisierter MAE sowie Median für die Schätzungen kontinuierlicher Größen für den Betrieb der RLT-Geräte im GSHN-Gebäude (Testzeitraum)

<sup>19</sup> Ein F1-Score von 100% entspricht einer idealen Schätzung.

## 5. Darstellung und Analyse der Ergebnisse

Für das Stellsignal des Heizregisterventils ( $U_{HR,Ventil}$ ), die Temperaturen der Fort- ( $T_{FOL}$ ) und Außenluft ( $T_{AUL}$ ) sowie die Zu- ( $\dot{V}_{ZUL}$ ) und Abluftvolumenströme ( $\dot{V}_{ABL}$ ) indizieren Mediane unter 3,1% eine allgemein sehr gute Schätzung des Betriebsverhaltens. Eine differenzierte Betrachtung der RLT-Anlagen zeigt jedoch, dass einzelne Ergebnisse stark vom Median abweichen. Dies betrifft insbesondere die nMAEs für  $U_{HR,Ventil}$  der Fachräume (FA) sowie  $\dot{V}_{ZUL}$  und  $\dot{V}_{ABL}$  für die RLT-Anlage Sport (SPO). Die hohen Abweichungen für die Volumenströme  $\dot{V}_{ZUL}$  und  $\dot{V}_{ABL}$  sind auf veränderte Sollwerte außerhalb des Trainingszeitraumes zurückzuführen. Für  $U_{HR,Ventil}$  zeichnet hingegen eine schlechtere Modellperformance verantwortlich. Im Vergleich zu den anderen RLT-Anlagen können tendenziell größere Ventilöffnungen mit absolut höheren Abweichungen der Schätzung beobachtet werden. Exemplarische Zeitreihenverläufe sind in Abbildung 40 dargestellt. Die Schätzung für die Anlage FA zeigt einen konstanten Offset von ca. -0.1, während die prognostizierte Zeitreihe für die Anlage SPO gut mit den observierten Daten übereinstimmt.




Abbildung 40: Exemplarische Zeitreihen der observierten und geschätzten Verläufe für das Stellsignal des Heizregisterventils ausgewählter RLT-Anlagen der GSHN.

Die übrigen Schätzgrößen weisen eine deutlich breitere Streuung der anlagenspezifischen nMAE-Werte, was zu höheren Medianen führt. Insbesondere für die Schätzgrößen der Zu- ( $T_{ZUL}$ ) und Ablufttemperaturen ( $T_{ABL}$ ) sowie der Vor- ( $T_{HR,hyd,VL}$ ) und Rücklauftemperaturen ( $T_{HR,hyd,RL}$ ) im hydraulischen Kreislauf des Heizregisters sind größere Fehler zu beobachten. Dies verdeutlicht die Interaktion mit anderen Komponenten der HLK-Anlage. Geänderte Sollwertparameter für die Raumluft (statisches Heizsystem) und die Vorlauftemperatur der zentralen Wärmeversorgung führen zu einem signifikant anderen Betriebsverhalten. Abbildung 41 zeigt die Regressionskurven 2. Ordnung für die Vorlauftemperaturen der RLT-Anlage FLA in Abhängig der Außenlufttemperatur (Heizkurve). Im Vergleich zum Trainings- und Validierungszeitraum (blau) ist im Testzeitraum (rot) ein deutlich stärkerer Anstieg bei niedrigeren Außenluft-

temperaturen zu erkennen ( $\Delta T_{HR,hyd,VL} = 10^{\circ}\text{C}$  bei  $T_{AUL} = 0^{\circ}\text{C}$ ). Abbildung 42 (links) veranschaulicht den Einfluss auf die Ablufttemperatur. Mit Beginn des Heizbetriebes (ca. 10 Uhr), führt dies zu einem im Vergleich zum Trainingszeitraum veränderten Temperaturniveau und einer verschlechterten Schätzqualität.




Abbildung 41: Regressionen für die Heizkurve auf Basis der Vorlauftemperatur im hydraulischen Kreislauf des Heizregisters der RLT-Anlage FLA (GSHN) für den Trainings- und Validierungszeitraum sowie den Testzeitraum. Grundlage für die Regression sind stündliche Mittelwerte der Daten im Heizbetrieb. Neben der Regressionskurve ist das Konfidenzband (95%) der Regression sowie der Mittelwerte (Punkte) über diskrete Abschnitte der x-Achse dargestellt.




Abbildung 42: Exemplarische Zeitreihendarstellung der observierten und geschätzten Verläufe für die Ablufttemperatur ausgewählter RLT-Anlagen der GSHN.

Eine globale Betrachtung der Schätzgüte ermöglichen die in Tabelle 18 dargestellten Mittelwerte der nMAE für die einzelnen Auswerteziträume und RLT-Anlagen. Dabei zeigt sich, dass im Mittel für alle RLT-Anlagen mit nMAE im Bereich von 2,6% bis 4% ähnlich gute Trainingsergebnisse erzielt werden. Auch im Testzeitraum liegen die nMAE mit Werten zwischen 5,1% und 6,8% auf einem niedrigen Niveau und damit nahe an den Ergebnissen des Trainingsdatensatzes. Zusammenfassend lässt sich feststellen, dass die allgemein guten Ergebnisse für die Schätzung des nominalen Betriebsverhaltens der RLT-Anlagen im GSHN-Gebäude, durch eine hohe Datenverfügbarkeit (langer Trainingszeitraum), eine ausreichende Präsenz der möglichen Be-

## 5. Darstellung und Analyse der Ergebnisse

---

triebsmodi in den Trainingsdaten (siehe Abschnitt 4.1.2) und eine nachvollziehbare Regelstrategie mit wenigen Ausnahmebedingungen begünstigt wird. Einschränkungen bestehen jedoch hinsichtlich veränderter Sollwerte im HKL-System außerhalb der observierten Systemgrenzen.

*Tabelle 18: Mittelwerte der normalisierten MAE je Auswertezeitraum für die Schätzungen der RLT-Anlagen im GSHN-Gebäude.*

RLT-Anlage	Mittlerer normalisierter MAE je Auswertezeitraum		
	Training	Validierung	Testen
FLA	2,60%	5,80%	5,10%
FLB	2,82%	5,46%	5,94%
FLC	2,44%	4,35%	4,37%
FA	2,54%	5,86%	4,56%
AUL	3,01%	6,12%	4,86%
SPO	2,90%	4,40%	4,00%

### 5.1.3. Maison du Savoir

Die Modellbildung und Aufbereitung der Ergebnisse für das Maison du Savoir (MSA) erfolgt analog zur Fallstudie GSHN. Es unterscheiden sich jedoch aufgrund der Datenverfügbarkeit die Länge der Trainings- (sechs Monate), Validierungs- (sechs Monate) und Testzeiträume (drei Monate) deutlich (siehe Abschnitt 4.2.2). Ergänzend zu den realen Anlagen wird in dieser Fallstudie die Performance für einen synthetischen Datensatz analysiert, der mithilfe eines physikalischen Systemmodells der RLT-Anlage AUD8 (siehe Abschnitt 4.2.3) generiert wird. Die Ergebnisse für den normalisierten mittleren absoluten Fehler (nMAE) sind in Abbildung 43 dargestellt. Tabelle 19 listet zudem die Mittelwerte der nMAE über alle Schätzgrößen für jeden Datensatz und Auswertezeitraum.



## 5. Darstellung und Analyse der Ergebnisse




Abbildung 43: Normalisierte MAE sowie der Median für die Schätzungen kontinuierlicher Größen der RLT-Geräte im MSA-Gebäude (Testzeitraum)

Tabelle 19: Mittelwerte der normalisierten MAE je Auswertezeitraum für die Schätzungen der RLT-Anlagen im GSHN-Gebäude

RLT-Anlage	Mittlerer normalisierter MAE je Auswertezeitraum		
	Training	Validierung	Testen
Synthetischer Datensatz	1,27%	1,38%	1,44%
AUD2	2,29%	3,75%	12,00%
AUD4	2,60%	3,87%	6,10%
AUD7	3,90%	6,74%	7,17%
AUD8	2,36%	4,04%	4,21%
AUD9	2,32%	5,95%	9,60%
AUD11	2,82%	4,70%	9,08%

Es zeigt sich, dass für den synthetischen Datensatz die höchste Schätzgüte für das nominale Verhalten erreicht wird. Die nMAEs liegen mit einem Bereich von 0,4% bis 4,3% und einem Mittelwert von 1,4% (Testzeitraum) über alle Schätzgrößen auf einem niedrigen Niveau. Im Vergleich dazu liegen alle Mittelwerte für die Testdatensätze aus dem realen Betrieb oberhalb von 6,1% (siehe Tabelle 19). Dieser signifikante Unterschied ist auf mehrere Faktoren zurückzuführen. Die verfügbare Zeitspanne für das Training (ein Jahr) sowie für die Validierung und das Testen (jeweils sechs Monate) ist beim synthetischen Datensatz wesentlich größer (jeweils ein Jahr), wodurch ein besseres Modelltraining und eine genauere Auswertung ermöglicht wird.

## 5. Darstellung und Analyse der Ergebnisse

Außerdem begünstigt das Fehlen stochastischer Effekte, wie der Nutzereinfluss und unbekannte Randbedingungen (z.B. Umgebungstemperatur am Aufstellort der RLT-Anlage) eine präzise Schätzung. Der synthetische Datensatz enthält zudem keine Kühlbetrieb-Zustände, was die Komplexität des Systemverhaltens reduziert.

Weiterhin ist zu beachten, dass es sich beim beobachteten System um einen geschlossenen Regelkreis handelt, dessen Regelverhalten vom ML-Modell erlernt werden muss. Da die implementierten Regelungsstrategien für die RLT-Geräte im MSA-Gebäude nicht dokumentiert sind, müssen für die Erstellung des physikalischen Anlagen-Modells sinnvolle Abhängigkeiten anhand der Betriebsdaten abgeleitet werden. Daher ist die Regelstrategie des synthetischen Datensatzes wesentlich einfacher strukturiert und daher leichter erlernbar.

Abbildung 44 zeigt beispielhafte Tagesverläufe im Testzeitraum für die geschätzten und beobachteten Werte der Zulufttemperatur und des Stellsignals des Heizregisterventils. Wie bei anderen Zielvariablen wird der dynamische Verlauf mit hoher Genauigkeit abgebildet, einschließlich des Aufheizvorgangs am Morgen und der Sollwertregelung im Tagesverlauf.




Abbildung 44: Beispielhafte Tagesverläufe im Testzeitraum für die Schätzung der Zulufttemperatur und des Stellsignals für das Heizregisterventil auf Basis des synthetischen Datensatzes.

Erwartungsgemäß sinkt die Schätzungsgüte bei der Anwendung auf reale Datensätze. Es zeigt sich eine breite Streuung der nMAE, sowohl beim Vergleich der RLT-Anlagen als auch bei der Betrachtung einzelner Systemgrößen. Mit Medianen zwischen 9% und 14% sind die Schätzungen für die Raumlufttemperatur ( $T_{Raum}$ ), die Ablufttemperatur ( $T_{ABL}$ ), die Außenluftfeuchte ( $rF_{ABL}$ ) und das Stellsignal für die Wärmerückgewinnung ( $U_{WRG}$ ) mit den größten Unsicherheiten behaftet. Eine Analyse der zeitlichen Verläufe zeigt, dass die Qualität insbesondere in den Sommermonaten bei warmen Außenluftbedingungen abnimmt. Abbildung 45 veranschaulicht exemplarisch die Verläufe an

zwei unterschiedlichen Tagen für die Schätzung der Außenluftfeuchte für die RLT-Anlage AUD8. Hohe Abweichungen sind am dargestellten Sommertag bei niedrigen relativen Luftfeuchten unterhalb von 40% zu beobachten.




Abbildung 45: Beispielhafte Tagesverläufe im Testzeitraum für die Schätzung der Außenluftfeuchte (RLT-Anlage AUD8, MSA-Gebäude).

Die besten Performances werden für das Stellsignal des Heizregisterventils ( $U_{HR,Ventil}$ ) und die Umluftklappe ( $U_{Umluft}$ ) mit Medianen kleiner 1% erzielt. Für die übrigen Größen liegen die Mediane in einem Bereich von 4% bis 7%. Auch hier sind die Abweichungen hauptsächlich auf den Sommerbetrieb zurückzuführen. Abbildung 46 verdeutlicht den Unterschied der Schätzgüte im Winter- und Sommerbetrieb anhand der Zulufttemperatur von RLT-Anlage AUD8. Im rechten Diagramm durchläuft die Anlage sowohl den Heiz-, als auch den Frischluftmodus, was durch einen großen Temperaturbereich für die Zulufttemperatur charakterisiert ist. Die maximale Abweichung beträgt 0,82 K, während die durchschnittliche absolute Abweichung 0,05 K beträgt. Das linke Diagramm zeigt den Verlauf für einen Sommertag. Die sprunghafte Veränderung der Zulufttemperatur, bedingt durch vorübergehend erhöhte Luftvolumenströme, wird grundsätzlich wiedergegeben, jedoch ist ein kontinuierlicher Offset zu beobachten. Während diesen Zeiträumen arbeitet das System im adiabaten Kühlmodus, der vom Regressionsmodell mit einer Spitzenabweichung von 2,4 K unzureichend abgebildet wird.

Aufgrund der Gebäudenutzung und den daraus resultierenden Schließzeiten werden die RLT-Anlagen in den Sommermonaten nur selten betrieben, wodurch das Betriebsverhalten bei hohen Außenlufttemperaturen nur unzureichend erlernt werden kann. Gleichzeitig liegt der Testzeitraum (Juli bis Oktober) überwiegend in den wärmeren Monaten, was folglich einen negativen Einfluss auf die ausgewerteten Metriken hat.

## 5. Darstellung und Analyse der Ergebnisse




Abbildung 46: Beispielhafte Tagesverläufe im Testzeitraum für die Schätzung der Zulufttemperatur im Heiz- und im Kühlbetrieb (RLT-Anlage AUD8, MSA-Gebäude).

Dies erklärt auch die signifikante Zunahme der mittleren nMAE über alle Schätzgrößen der jeweiligen RLT-Anlage (siehe Tabelle 19). Während im Validierungszeitraum die mittleren nMAE zwischen 4% (AUD2) und 7% (AUD7) liegen, steigen sie im Testzeitraum in einen Bereich von 4% (AUD8) bis 12% (AUD2). Besonders für die Anlage AUD2 verschlechtert sich die Schätzqualität, mit einem Anstieg von 4% auf 12%, sehr stark. Bei dieser Anlage kann zusätzlich eine veränderte Volumenstromregelung im Testzeitraum beobachtet werden.




Abbildung 47: F1-Score sowie Median für die Schätzungen diskreter Größen der RLT-Geräte im MSA-Gebäude (Testzeitraum)

Für diskrete Größen zeigt Abbildung 47 den resultierenden F1-Score der Schätzungen im Testzeitraum. Im Gegensatz zum realen Betrieb wurde für die Generierung des synthetischen Datensatz eine diskrete Stufenregelung des Volumenstroms umgesetzt, sodass für diesen Datensatz auch die Stellsignale der Ventilatoren aufgeführt sind ( $U_{ZUL-Ven}$ ,  $U_{ABL-Ven}$ ). Die adiabate Kühlfunktion und Umluftbetrieb ( $U_{ADC, Pu}$ ,  $U_{Umluft}$ ) sind im synthetischen Datensatz nicht enthalten. Der resultierende F1-Score zeigt mit Werten oberhalb von 97% für alle Größen eine gute Schätzung. Ausgenommen sind die Stellsignale des Heizregisterventils und für die Pumpe der adiabaten Kühlung von Anlage AUD11, mit F1-Scores von 83% und 56%. Die schlechte Schätzung für die

Pumpe lässt sich darauf zurückführen, dass im Trainingsdatensatz der Anlage AUD11 kein Kühlbetrieb enthalten ist.

Die aufgeführten Beispiele zeigen, dass die neuronalen MLP-Netze das dynamische Verhalten der Zielvariablen im MSA-Gebäude grundsätzlich abbilden können, jedoch nicht alle Betriebsmodi gleichermaßen gut geschätzt werden. Verantwortlich hierfür sind die unterschiedlichen Anteile in den Trainingsdaten. Beispielsweise ist in den Daten der Anlage AUD8 der Kühlmodus mit einem Anteil von 1,4% stark unterrepräsentiert (siehe Abbildung 32 in Abschnitt 4.2.2) und kann daher nur unzureichend durch das ML-Verfahren erlernt werden. Gleichzeitig steigt der Anteil im Testzeitraum auf 7,9%. Der Datensatz der Anlage AUD7 (Abbildung 31 in Abschnitt 4.2.2) zeigt zusätzlich eine starke Zunahme des Frischluftbetrieb von ca. 40% im Trainingszeitraum auf 60% im Testzeitraum, während der Heizbetrieb anteilig weniger vertreten ist. Diese Verschiebung der Anteile erklärt die sehr unterschiedlichen Ergebnisse für die mittleren nMAE in den jeweiligen Zeiträumen (Tabelle 19), die maßgeblich durch die Verteilung der Betriebsmodi beeinflusst werden.

### 5.1.4. Anonymisierte Liegenschaft

Die untersuchten RLT-Anlagen der anonymisierten Liegenschaft (ISC) sind durch eine sehr unterschiedliche Nutzung der Versorgungszone geprägt. Daraus resultieren ungleichen Anforderungen an die Systeme und folglich eine variierende Anzahl und Typen der verfügbaren Datenpunkte.

Die Anlagen CTA01 und CTA03 sind funktional identisch und besitzen weder eine Heiz- noch eine Kühlfunktion. Für diesen einfachen Anlagentyp werden erwartungsgemäß die besten Schätzungen mit mittleren normalisierten absoluten Fehlern (nMAE) von 2,0% und 3,5% erreicht (siehe Tabelle 20). Die leicht schlechtere Performance für Anlage CTA03 lässt sich im Wesentlichen auf eine andere Lage der Versorgungszone innerhalb des Gebäudes und damit verbunden einer höheren Varianz in der Ablufttemperatur erklären. Dies führt in allen Schätzgrößen zu einer leichten Abnahme der Performance (siehe Abbildung 48). Eine größere Abweichung von ca. 6% ist für die Schätzgröße  $U_{ABL-Ven}$  (Stellsignal Ventilator) zu beobachten. Trotz einer ähnlichen Charakteristik des zeitlichen Verlaufes für  $U_{ABL-Ven}$ , lässt sich für Anlage CTA03 ein schlechteres Trainingsergebnis und damit grundsätzlich schlechtere Schätzungen identifizieren. Einen exemplarischen Tagesverlauf beider Schätzungen zeigt Abbildung 49.

## 5. Darstellung und Analyse der Ergebnisse

Tabelle 20: Mittelwerte des normalisierten MAE je Auswertezeitraum für die Schätzungen der RLT-Anlagen im ISC-Gebäude.

RLT-Anlage	Mittlerer normalisierter MAE je Auswertezeitraum		
	Training	Validierung	Testen
CTA01	1,97%	2,12%	1,97%
CTA02	3,12%	4,73%	4,43%
CTA03	2,79%	3,35%	3,53%
CTA08	4,16%	5,11%	5,17%
CTA17	2,62%	3,21%	4,28%




Abbildung 48: Normalisierter MAE sowie der Median für die Schätzungen kontinuierlicher Größen der RLT-Geräte im ISC-Gebäude (Testzeitraum)




Abbildung 49: Exemplarischer Tagesverlauf der Schätzgröße  $U_{ABL-Ven}$  (Stellsignal Ventilator) für die Anlagen CTA01 und CTA03.

Ebenfalls gute Ergebnisse mit einem mittleren nMAE von ca. 4% werden für die Schätzgrößen der Anlage für den Wohnbereich des Internats (CTA17) erzielt. Die Betriebscharakteristik wird durch einen dauerhaften Betrieb mit wenig transienten Zuständen geprägt, wodurch das nominale Systemverhalten mit geringen Abweichungen prognostiziert werden kann. Eine Ausnahme ist die Schätzung für einen Drucksensor im Abluftkanal ( $P_{ABL,Sens}$ ) mit einem nMAE von 21%. Der Grund hierfür ist ein kontinuierlicher Anstieg des Messwerts über die Laufzeit der Anlage (Sensordrift). Abbildung 50 zeigt den jährlichen Median der Daten im eingeschalteten Zustand für den Drucksensor und den Kanaldruck des Ventilators ( $P_{ABL,Ven}$ ). Während für den Drucksensor ein kontinuierlicher Anstieg zu beobachten ist, verbleibt der Kanaldruck des Ventilators auf einem gleichbleibenden Niveau.




Abbildung 50: Liniendiagramm für den Druck im Abluftkanal erfasst durch einen Sensor (rot) und die Ventilatorsteuerung (blau). Dargestellt ist der jährliche Median im eingeschalteten Zustand der Anlage.

Allgemein lässt sich feststellen, dass im ISC-Gebäude der mittlere nMAE für den Testzeitraum nahe an den Ergebnissen für den Validierungszeitraum liegen (Tabelle 20). Eine manuelle Analyse der Betriebsdaten zeigt, dass die RLT-Anlage ohne größere Veränderungen der Sollwertvorgaben oder Regelcharakteristik im Betrachtungszeitraum betrieben werden, wodurch eine zuverlässige Schätzung im Testzeitraum ermöglicht wird. Auch für Datensätze mit höherer Varianz der Daten aufgrund der Nutzung und Ausstattung der RLT-Anlagen (CTA02 und CTA08) werden mit mittleren nMAE von etwa 5% gute Schätzungen erzielt. Dieser Trend wird durch die in Abbildung 51 dargestellten F1-Scores für die Schätzungen der diskreten Größen bestätigt. Das Minimum liegt bei 94,3 % für die Pumpe im hydraulischen Kreislauf des Heizregisters von Anlage CTA02, was ein sehr hohes Niveau darstellt.

## 5. Darstellung und Analyse der Ergebnisse




Abbildung 51: F1-Score sowie der Median fur die Schatzungen diskreter Groen der RLT-Gerate im ISC-Gebaude (Testzeitraum)

### 5.1.5. Einflussfaktoren auf die Schatzqualitat

Die Schatzqualitat von selbstlernenden Modellen basierend auf historischen Betriebsdaten wird mageblich durch die Groe und Qualitat der Trainingsdaten beeinflusst. Fur die praktische Anwendung ist es daher notwendig Empfehlungen hinsichtlich der Mindestanforderungen an die Datengrundlage fur ein hinreichend gutes Modelltraining zu formulieren. Vor diesem Hintergrund werden in den folgenden Abschnitten der Einfluss fehlerhafter Betriebszustande in den Trainingsdaten (Abschnitt 5.1.5.1) und die Lange des Trainingszeitraums (Abschnitt 5.1.5.2) auf die Schatzqualitat naher untersucht.

#### 5.1.5.1. Fehlerhafte Betriebszustande in den Trainingsdaten

Fehlerhafte Betriebszustande in den historischen Betriebsdaten, konnen sowohl das Modelltraining als auch die Performancebewertung beeinflussen. In der Trainingsphase ist es moglich, dass wiederkehrende Fehlerzustande durch das ML-Modell erlernt werden. Treten dieselben Fehlertypen auch im Testzeitraum auf, fuhrt dies zu einer Vorhersage des fehlerhaften Verhaltens und einer Abnahme der Residuen-Signifikanz. In diesem Fall ist ein Modell mit scheinbar guter Performance fur eine Fehlererkennung und -diagnose moglicherweise ungeeignet. Die Performancebewertung wird hingegen durch den Fehleranteil im Testdatensatz beeinflusst. Fehlerhafte Zustande konnen zu hohen Residuen und damit einer Verschlechterung der ausgewerteten Metriken fuhren, obwohl das nominale Verhalten mit einer hohen Genauigkeit abgebildet wird.

Um den Einfluss fehlerhafter Betriebszustande auf die Modellperformance zu analysieren, wird das Modelltraining mit einer vorherigen Filterung der fehlerhaften Betriebszustanden in den Datensatzen durchgefuhrt und der Performancebewertung aus den Abschnitten 5.1.2 bis 5.1.4 gegenubergestellt. Fur die Filterung werden die Ergebnisse



des Labeling-Prozesses aus Abschnitt 3.6 herangezogen. Die Berechnung des nMAE zur Performancebewertung erfolgt für beide Trainingsvarianten auf Basis des gefilterten Testdatensatzes, der das fehlerfreie Verhalten repräsentiert. Zudem wird ein einheitlicher Wertebereich für die Normalisierung des MAE verwendet.

Die Veränderung des Medians für den nMAE der Fallstudien sowie die Fehleranteile in den Trainings- und Testdaten zeigt Abbildung 52. Für 11 der insgesamt 17 betrachteten RLT-Anlagen kann durch das Filtern eine Verbesserung für die Schätzung des nominalen Verhaltens erzielt werden. Die Veränderungen sind mit Werten weniger als 1% als gering einzustufen. Eine Korrelation zwischen den Fehleranteilen und der Veränderung des nMAE ist nicht zu erkennen. Da das Modelltraining durch stochastische Prozesse<sup>20</sup> geprägt ist, sind auch bei geringen Fehleranteilen in den Datensätzen Veränderungen in der Schätzgüte zu beobachten. Zudem führt das Filtern der Fehlerzustände zu einer Verkleinerung der Datensätze mit geringerer Varianz, wodurch die generalisierende Eigenschaft eines Modells abnimmt. Dieser Effekt zeigt sich deutlich für die RLT-Anlage AUD11 im MSA-Gebäude. In dieser Fallstudie führt eine signifikante Veränderung der Luftvolumenströme zu einer starken Abnahme der Modellperformance im Testzeitraum. Durch das Filtern der Trainingsdaten wird der Gültigkeitsbereich des Modells stärker auf das nominale Verhalten im Trainingszeitraum beschränkt, wodurch der Median des nMAEs um weitere 3,8% zunimmt. Für die FED ist dieser Effekt jedoch vorteilhaft, da sich im Fehlerfall höhere Residuen ausprägen. Der Einfluss auf die Residuen im Fehlerzustand ist beispielhaft für eine kontinuierliche und diskrete Variable der RLT-Anlage AUD7 in Abbildung 53 dargestellt. Durch die Filterung der Daten verschiebt sich die relative Häufigkeit der Residuen-Beträge in einen höheren Wertebereich.

Zusammenfassend lässt sich feststellen, dass fehlerhafte Betriebszustände in den Trainingsdaten keinen signifikanten Einfluss auf die Schätzung des nominalen Betriebsverhaltens haben. Eine Filterung der Fehlerzustände beschränkt jedoch den Gültigkeitsbereich des Modells auf den im Trainingsdatensatz vorhanden nominalen Betriebsbereich und erzielt somit eine stärkere Ausprägung der Symptome (Residuen) im Fehlerfall. Ein Nachteil der abnehmenden Generalisierung ist, dass möglicherweise

---

<sup>20</sup> Stochastische Effekte treten beispielsweise durch die zufällige Auswahl initialer Modellparameter oder das zufällige Auslassen einzelner Modellparameter im Trainingsprozess (sogenanntes „Dropout“) auf. Im Modellierungsprozess werden daher einheitliche Zufalls-Seeds gesetzt, um möglichst deterministische Ergebnisse zu erzielen. Dennoch können bei der Wiederholung eines Experiments geringfügige Abweichungen in den Ergebnissen auftreten.

## 5. Darstellung und Analyse der Ergebnisse

auch das nominale Verhalten schlechter geschätzt wird. Insbesondere für Betriebs-situationen, die in den Trainingsdaten nicht (ausreichend) vertreten sind.




Abbildung 52: Veränderung des Medians für den normalisierten absoluten Fehler (nMAE) durch das Filtern fehlerhafter Betriebszustände in den Trainingsdaten der untersuchten Fallstudien.




Abbildung 53: Relative Häufigkeitsverteilung im Fehlerfall für die Residuen-Beträge der Systemgrößen  $T_{ZUL,nWRG}$  und  $U_{Umluft}$  der RL-Anlage AUD7 im MSA-Gebäude. Dargestellt sind die Ergebnisse ohne eine Filterung der fehlerhaften Betriebszustände für das Modelltraining (blau) und mit einer Filterung (rot).

### 5.1.5.2. Länge des Trainingszeitraums

Die Ergebnisse für die Schätzung des nominalen Betriebsverhaltens der Fallstudien zeigen, dass die Modellperformances für die RLT-Anlagen im MSA-Gebäude im Vergleich zum GSHN- und ISC-Gebäude grundsätzlich schlechter ausfallen. Ein wesentlicher Unterschied sind die verfügbaren Zeiträume für das Modelltraining. Während für das MSA-Gebäude lediglich sieben Monate genutzt werden, erfolgt das Training in den übrigen Fallstudien auf einer Datenbasis von einem Jahr. Der Einfluss der verfügbaren historische Datenbasis auf die Schätzqualität stellt somit eine wichtige Fragestellung für die Interpretation der Ergebnisse und die praktische Anwendung der FED-Methodik.

Der Einfluss des Trainingszeitraums auf die Performance im Testzeitraum wird exemplarisch anhand der RLT-Anlagen FLA im GSHN-Gebäude und CTA17 im ISC-Gebäude näher untersucht. Hierzu wird der Zeitraum beginnend am 01.01. schrittweise um zwei Monate verlängert, bis ein Zeitraum von 1,5 Jahren (18 Monate) erreicht wird. Der Trainingsdatensatz beinhaltet die Betriebsdaten im fehlerfreien und eingeschalteten Zustand der Anlage, wodurch der Einfluss fehlerhafter Daten auf die Schätzqualität (siehe Abschnitt 5.1.5.1) eliminiert wird. Dies bedeutet jedoch auch, dass die verfügbare Datenmenge nicht linear mit der schrittweisen Verlängerung des Zeitraums steigt. Insbesondere in Schulbauten kommt hinzu, dass die gebäudetechnischen Anlagen in Ferienzeiten häufig ausgeschaltet sind und in den betreffenden Monaten die Datenverfügbarkeit sinkt.

Abbildung 54 und Abbildung 55 zeigen den Mittelwert des normalisierten Fehlers (nMAE) sowie den Min-Max-Bereich der Schätzgrößen in Abhängigkeit vom Trainingszeitraum. Aufgrund des beobachteten Sensor drifts für den Kanaldruck in der Abluft der RLT-Anlage CTA17 wird die korrespondierende Schätzung für eine bessere Interpretation der Ergebnisse in der Berechnung der dargestellten Größen nicht berücksichtigt. Beide Fallstudien zeigen eine deutliche Performancesteigerung bis zu einem Zeitraum von sechs Monaten. Während für die Anlage FLA ein nMAE von 6,85% erreicht wird, erzielen die MLP-Modelle für CTA17 einen mittleren nMAE von 3,06%. Mit zunehmender Erweiterung des Trainingsdatensatzes verändert sich die Modellperformance nur geringfügig. Hieraus lässt sich ableiten, dass ein Mindestzeitraum von sechs Monaten für die Modellierung des nominalen Systemverhaltens notwendig ist. Es ist jedoch zu beachten, dass der Startzeitpunkt des Trainingszeitraums die erforderliche Zeitspanne beeinflussen kann. In dieser Untersuchung decken die ersten sechs Monate sowohl

## 5. Darstellung und Analyse der Ergebnisse

Tage mit sehr kalten klimatischen Randbedingungen (Januar) als auch sehr warmen (Juni) ab. Beginnt der Zeitraum jedoch beispielsweise im April, könnte das Betriebsverhalten bei sehr niedrigen Außentemperaturen in den ersten sechs Monaten möglicherweise nicht ausreichend erlernt werden.




Abbildung 54: Mittelwert des normalisierten Fehlers für alle Schätzgrößen der Anlage FLA im GSHN-Gebäude für unterschiedliche Trainingszeiträume. Die vertikalen Linien markieren den Wertebereich der individuellen Ergebnisse (oben). Im unteren Diagramm ist die Anzahl der verfügbaren Datensätze für das Training dargestellt.




Abbildung 55: Mittelwert des normalisierten Fehlers für alle Schätzgrößen der Anlage CTA17 im ISC-Gebäude für unterschiedliche Trainingszeiträume. Die vertikalen Linien markieren den Wertebereich der individuellen Ergebnisse (oben). Im unteren Diagramm ist die Anzahl der verfügbaren Datensätze für das Training dargestellt.

Dennoch zeigt sich anhand der RLT-Anlage FLA, dass ein längerer Trainingszeitraum vorteilhaft sein kann. Der maximale Fehler der individuellen Schätzungen sinkt kontinuierlich mit einer zunehmenden Vergrößerung des Trainingszeitraums von ca. 20% bei 6 Monaten auf unter 10% bei 14 Monaten (ca. 30.000 Datensätze). Eine Ausnahme bildet der Zeitraum für 12 Monate. Hier zeichnet die Schätzung der Ablufttemperatur für einen einmaligen Anstieg des maximalen Fehlers verantwortlich. Bedingt durch die stochastischen Einflüsse im Trainingsprozess wurden hier möglicherweise nicht die optimalen Hyperparameter gefunden. Zudem kann ab einem Zeitraum von 16 Monaten eine weitere Verbesserung des mittleren nMAE in einen Wertebereich unterhalb von 5% erreicht werden. In den Ergebnissen der RLT-Anlage CTA17 ist hingegen keine nennenswerte Steigerung der Performance für Trainingszeiträume größer sechs Monate erkennbar. Dies kann auf eine sehr konstante Betriebsweise mit wenigen möglichen Betriebszuständen (Frischluf- und Heizbetrieb, siehe Abbildung 94 in Anhang A10) und eine hohen Datenverfügbarkeit innerhalb der ersten sechs Monate (siehe Abbildung 55 unten) zurückgeführt werden. Leichte Schwankungen in den Ergebnissen sind aufgrund der veränderten Datenverteilung abhängig vom Zeitraum möglich.

Für die Fallstudien aus dem MSA-Gebäude lässt sich aus den Beobachtungen ableiten, dass die schlechtere Modellperformance hauptsächlich auf das komplexere Systemverhalten zurückzuführen ist, wodurch eine größere Datenverfügbarkeit zum Erlernen des nominalen Verhaltens notwendig wird. In der praktischen Anwendung muss die Länge des Trainingszeitraums daher abhängig von der Komplexität und dem Startzeitpunkt gewählt werden, wobei als Mindestanforderung ein Zeitraum von 6 Monaten definiert werden kann. Zur Minimierung der individuellen Fehler für die einzelnen Schätzgrößen und zur Gewährleistung eines zuverlässigen Modelltrainings sind Zeiträume länger als 12 Monate zu empfehlen.

### 5.1.6. Zusammenfassung und Diskussion

Der vorgestellte Entwurf zur Schätzung des nominalen Betriebsverhaltens von RLT-Anlagen, basierend auf Multi-Layer-Perceptron-Modellen (MLP), zeigt in der Anwendung auf insgesamt 17 Fallstudien mit realen Datensätzen eine generell gute Eignung für den Einsatz in einem Residuen-generierenden FED-Ansatz. Besonders hervorzuheben ist, dass auch ohne individuelle Anpassung der (Hyper-)Parameter aussagekräftige Schätzungen erzielt werden. Dies gewährleistet zum einen eine hohe Übertragbarkeit und ermöglicht zum anderen die Anwendung ohne tiefgehendes Expertenwissen im Bereich des maschinellen Lernens (ML).

## 5. Darstellung und Analyse der Ergebnisse

Für die Entwicklung und das Testen von FED-Ansätzen auf Basis historischer Betriebsdaten ist die Verfügbarkeit gelabelter Datensätze entscheidend. Da reale Datensätze oft keine Labels enthalten, können synthetische Datensätze aus physikalischen Systemmodellen hilfreich sein, um bekannte Fehlerzustände zu simulieren. Eine Untersuchung am Ersatzmodell der RLT-Anlage AUD8 zeigt jedoch, dass ML-Ansätze basierend auf synthetischen Daten deutlich bessere Schätzungen liefern. Verlässliche Rückschlüsse auf die Performance in realen Anwendungen sind jedoch nicht möglich, da diese durch höhere Varianz und stochastische Eigenschaften der Daten geprägt sind.

Die wesentlichen Arbeitsschritte beim initialen Training der Modelle umfassen das Festlegen des Trainingszeitraums und das Filtern fehlerhafter Betriebszustände aus den Datensätzen. Ziel ist es, eine weitgehend fehlerfreie Datengrundlage mit hoher Varianz möglicher nominaler Betriebszustände für das Modelltraining zu schaffen. Obwohl dieser Prozess nur einen geringen Einfluss auf die Schätzung des nominalen Verhaltens hat (siehe Abbildung 56), wird die Modellgültigkeit auf den nominalen Bereich beschränkt. Dies führt zu einer stärkeren Ausprägung der Residuen im Fehlerfall und beeinflusst somit die Qualität des gesamten FED-Prozesses empfindlich. Das Filtern fehlerhafter Betriebszustände ist in der Praxis zeitaufwändig und erfordert umfassendes Expertenwissen über das Betriebsverhalten von Lüftungsanlagen. Der Einsatz von Expertenregeln erweist sich hier als sinnvoll. Diese Regeln können häufig auftretende Fehler identifizieren, gewährleisten eine Mindestqualität der Trainingsdaten und reduzieren den Aufwand für die Datenauswahl erheblich.




Abbildung 56: Säulendiagramm für die gebäudespezifischen Mittelwerte der nMAEs für die Schätzungen des nominalen Betriebsverhaltens mit und ohne Filterung der Eingangsdaten. Die eingezeichneten Linien zeigen den Wertebereich der anlagenspezifischen Mittelwerte.

Große Unterschiede zeigen sich bei einer gebäudespezifischen Betrachtung der Schätzgüte (Abbildung 56). Die Lüftungsanlagen der GSHN, mit Ausnahme der Anlagen für die Sporthalle und die Aula, sind hinsichtlich Luftbehandlung, Regelungsstrategie, Nutzung der Versorgungszone und observiertes Betriebsverhalten ähnlich. Hieraus resultiert eine geringe Spannweite für die anlagenspezifische nMAE zwischen 4,0% und 5,5%. Eine andere Charakteristik zeigen die Daten für das MSA-Gebäude. Trotz identischer Nutzung und Ausstattung der RLT-Anlagen wird ein sehr unterschiedliches Betriebsverhalten beobachtet, was sich negativ auf die Schätzqualität auswirkt. Die Spannbreite der anlagenspezifischen nMAE-Werte reicht von 3,5% bis 11%, wobei der mittlere nMAE mit etwa 8% im Vergleich zum GSHN- und ISC-Gebäude auf einem deutlich höheren Niveau liegt. Dies ist hauptsächlich auf das Regelverhalten mit einer Vielzahl unterschiedlicher Bedingungen zurückzuführen, was häufig zu transienten Zuständen und wechselndem Betriebsverhalten bei geringen Schwellwertüberschreitungen führt. Der Betrieb der RLT-Anlagen im ISC-Gebäude kann demgegenüber als konstant charakterisiert werden und wird einem mittleren nMAE von ca. 4% deutlich besser geschätzt. Grundsätzlich lässt sich ableiten, dass das Betriebsverhalten von Anlagen mit wenig wechselnden Regelstrategien, einfacher technischer Ausstattung und einer geringen Anzahl möglicher Betriebszustände besser erlernt werden kann. Das bedeutet, dass die Konzeption der Anlagen, insbesondere die Regelung, sowie die Nutzung die Schätzgüte beeinflussen.

Aus Gründen der Vergleichbarkeit werden für allen Anlagen eines Gebäudes identische Trainings- und Validierungszeiträume gewählt. Die Auswertungen der anlagenspezifischen Ergebnisse in den Abschnitten 5.1.2 bis 5.1.4 zeigen jedoch, dass in der praktischen Anwendung die individuellen Besonderheiten der Anlagen hinsichtlich Sollwertänderungen, Häufigkeit der Fehlerzustände, Verteilung der Betriebsmodi, etc. bei der Auswahl der Zeiträume berücksichtigt werden müssen. Hierzu zählen auch Sollwertvorgaben außerhalb der Systemgrenzen, wie die Vorlauftemperatur der Wärmeversorgung oder die Raumtemperatur. Zudem können extreme Wetterereignisse wie Hitzeperioden, die nicht in den Trainingsdaten enthalten sind, die Performance in der Anwendung verschlechtern. Werden nicht repräsentative Zeiträume gewählt oder ändern sich Sollwertvorgaben oder andere Regelparameter während der Anwendungsphase, kann ein erneutes Modelltraining erforderlich werden.

Der Trainingsdatensatz sollte einen Zeitraum von mindestens sechs Monaten, idealerweise 12 bis 14 Monate, abdecken (siehe Abschnitt 5.1.5.2), um die jahreszeitlichen Betriebscharakteristiken anhand der historischen Daten ausreichend erlernen zu kön-

nen. In der praktischen Anwendung sind zu Beginn eines Projektes häufig nur begrenzte Trainingsdaten verfügbar. Daher beschränkt sich der Einsatz der vorgestellten FED-Methodik auf ein kontinuierliches technisches Gebäudemonitoring im einregulierten Betrieb.

Eine besondere Schwierigkeit besteht im Umgang mit driftenden Sensorwerten im Trainings- und Validierungszeitraum. Da es sich um einen kontinuierlichen Sensorfehler handelt, kann keine Filterung vorgenommen werden. Modelle, die mit einem driftenden Sensor trainiert wurden, müssen nach der Fehlerbehebung erneut trainiert werden. Dies erfordert einen Datensatz der eine ausreichend lange Periode mit dem neuen Betriebsverhalten abdeckt. Alternativ kann der betroffene Sensor vom Datensatz entfernt werden, wodurch das FED-Potential jedoch reduziert wird. In der Anwendungsphase führt ein Sensordrift zu einer kontinuierlichen Abnahme der Schätzqualität und damit ansteigenden Residuen. Abhängig vom Gradienten ist eine Identifizierung in der Praxis meist nur durch eine Auswertung längerer Zeiträume möglich. Ähnlich wirken steigende Druckverluste aufgrund zunehmender Verschmutzung der Luftfilter auf das Systemverhalten. In den untersuchten Fallstudien hat dieser Einfluss aufgrund der regelmäßigen Wartung (meist jährlich) der Anlagen keine sichtbaren Veränderungen des Systemverhaltens oder eine Abnahme der Schätzqualität verursacht.

Um eine hohe Übertragbarkeit und flexible, adaptive Modellbildung zu erreichen, werden weitestgehend alle verfügbaren Datenpunkte (Features) der beobachteten Anlage zur Schätzung des nominalen Verhaltens verwendet. Dies schließt auch Systemgrößen ein, die möglicherweise keine signifikante Wirkung auf die Zielgröße haben, was tendenziell zu komplexeren Modellstrukturen mit höheren Anforderungen an die Rechenleistung führt. Eine mögliche Lösung kann der Einsatz eines geeigneten Verfahrens zur Feature-Auswahl darstellen, wie bspw. Expertenregeln oder statistische Methoden wie die Bestimmung der (Kreuz-) Korrelationskoeffizienten. Ersteres erfordert jedoch ein komplexes Regelwerk, welches sowohl die Datenverfügbarkeit als auch die Anlagenkonfiguration berücksichtigen muss, während statistische Verfahren ausschließlich Wechselbeziehungen in den Daten beschreiben, die nicht mit der Beziehung im technischen System übereinstimmen müssen. Unabhängig vom gewählten Verfahren besteht die Gefahr, dass durch eine Feature-Auswahl Informationen über das Systemverhalten verloren gehen. Umgekehrt können zusätzliche zeitliche Merkmale wie Stunde am Tag, Wochentag oder Ferienzeiten hinzugefügt werden. Insbesondere bei Gebäuden mit ausgeprägten Nutzungsmustern kann dadurch der Informationsgehalt der Eingangsdaten erhöht und damit die Schätzung verbessert werden.



Der Einsatz von ML-Methoden in einem Residuen-generierenden FED-Ansatz ermöglicht eine zuverlässige Schätzung des nominalen Betriebsverhaltens. Die untersuchten Fallstudien zeigen jedoch, dass die Schätzunsicherheiten sowohl innerhalb eines einzelnen Systems als auch auf Anlagen- und Gebäudeebene stark variieren können. Vor diesem Hintergrund muss die implementierte Evaluierungsmethodik in einem automatisierten, Residuen-generierenden FED-Prozess in der Lage sein, sich selbstständig an die individuelle Schätzgüte der Systemvariablen anzupassen.

### 5.2. Residuen-Evaluierung und Fehlererkennung

Die Schätzungen des nominalen Verhaltens bilden die Grundlage für das in Abschnitt 3.4 beschriebene Verfahren zur Berechnung und Evaluierung der Residuen sowie der anschließenden Fehlererkennung. In diesem Abschnitt werden zunächst die Herausforderungen bei Evaluierung der Residuen und die Funktionsweise der Methodik anhand von Beispielen veranschaulicht (5.1.2 und 5.2.2), bevor die Ergebnisse der Fehlererkennung für die untersuchten Fallstudien (5.2.3 bis 5.2.5) analysiert werden. Anhand von charakteristischen Beispielen werden Ursachen für mögliche Abweichungen der FE zum wahren Fehlerstatus verdeutlicht. Danach folgen Performance-Vergleich mit einer FE basierend auf der L2-Norm des Residuen-Vektors (Abschnitt 5.2.6) sowie einem Expertensystem (Abschnitt 5.2.7). Anschließend werden die Ergebnisse zusammengefasst und diskutiert (Abschnitt 5.2.8).

#### 5.2.1. Herausforderungen in der Residuen-Evaluierung

Eine wesentliche Aufgabe und Herausforderung in der Residuen-Evaluierung besteht darin, zwischen Modellunsicherheiten und Fehlereinflüssen zu unterscheiden. Abbildung 57 zeigt die relative Häufigkeit der berechneten normalisierten Residuen im fehlerhaften (rot) und fehlerfreien Zustand (blau) für die Ablufttemperatur ( $T_{ABL}$ ) und das Stellsignal des WRG-Rades ( $U_{WRG}$ ) am Beispiel der RLT-Anlage AUD7 im MSA-Gebäude. Die Analyse verdeutlicht, dass sich eine große Anzahl der Residuen im fehlerbehafteten und fehlerfreien Betriebszustand überschneiden. Daraus folgt, dass eine eindeutige Entscheidung über den Fehlerzustand nicht allein auf Basis eines einzelnen Residuen-Wertes getroffen werden kann. Dies gilt auch für Schätzgrößen in denen sich einzelne Fehlertypen sehr stark ausprägen und eine Entscheidungsfindung vermeintlich einfach ist (siehe Beispiel  $U_{WRG}$  in Abbildung 57).

## 5. Darstellung und Analyse der Ergebnisse




Abbildung 57: Relative Häufigkeit der normierten Residuen im fehlerfreien (blau) und fehlerbehafteten Betriebszustand (rot) für die Ablufttemperatur (links) und das Stellsignal der WRG (rechts) am Beispiel der RLT-Anlage AUD7 im MSA-Gebäude.

Die Unsicherheiten werden maßgeblich durch das gewählte ML-Modell und seine Fähigkeit, das dynamische Verhalten des Systems zu beschreiben, beeinflusst. Eine sorgfältige Modellauswahl ist daher unerlässlich. Nichtsdestotrotz hängt die Genauigkeit der Schätzung maßgeblich von der Verteilung der historischen Daten und den darin repräsentierten Betriebsbedingungen ab. Im Kontext von Gebäudesystemen erfordert dies, dass der Trainingsdatensatz alle potenziellen klimatischen Bedingungen umfasst (siehe Abschnitt 5.1.5.2). Auch die implementierte Regelstrategie und die Art der Nutzung führen zu einer ungleichmäßigen Verteilung der Betriebsmodi. Beispielsweise können RLT-Geräte auf Basis von in den Steuerungsregeln definierten Temperaturgrenzen zwischen Heiz- und Kühlbetrieb umschalten. Infolgedessen beinhalten die Datensätze häufig Betriebsmodi, die anteilig stark unterrepräsentiert sind. In den untersuchten Fallstudien sind insbesondere der Umluft- und der Kühlbetrieb betroffen (siehe Abschnitte 4.1.2, 4.2.2 und 4.3.2), wodurch das Systemverhalten in diesen Modi unzureichend erlernt werden kann. In der Summe führen die Einflüsse zu stark variierenden und anlagenspezifischen Modellunsicherheiten. Abbildung 58 veranschaulicht die relative Häufigkeit der Residuen für unterschiedliche Betriebsmodi im fehlerfreien Zustand am Beispiel der Zulufttemperatur für die RLT-Anlage AUD8 im MSA-Gebäude. Es zeigt sich, dass die Streuung für den Heizbetrieb (rot) und insbesondere den Kühlbetrieb (blau) im Vergleich zum Frischluftbetrieb ohne Luftbehandlung (grau) deutlich zunimmt.




Abbildung 58: Relative Häufigkeitsverteilung der Residuen für die Zulufttemperatur der RLTA-Anlage AUD8 im MSA-Gebäude gegliedert in die Betriebsmodi Frischluftbetrieb ohne Luftbehandlung, Kühlbetrieb und Heizbetrieb. Dargestellt sind Daten im fehlerfreien Zustand.

HLK-Systeme sind mit mehreren Sensoren (Zustandsgrößen) und Aktoren (Stellgrößen) ausgestattet. Im Rahmen des Residuen-generierenden FED-Prozesses werden für diese Größen  $n$  Schätzungen mit einer entsprechenden Anzahl Residuen generiert. Die Fähigkeit, Fehler zu erkennen und zu diagnostizieren, verbessert sich mit der Anzahl der Residuen, da verschiedene Arten von Fehlern in unterschiedlichen Residuen Symptome hervorrufen. Ein klemmendes Ventil im Hydraulikkreislauf eines Heizregisters beeinflusst beispielsweise die Zulufttemperatur einer Lüftungsanlage stark, während der Kanaldruck unverändert bleibt. Im Idealfall erzeugt jeder Fehler ein eindeutiges Muster im Residuen-Vektor, wodurch neben der Fehlererkennung auch eine Fehlerisolierung ermöglicht wird.

Eine Schwierigkeit besteht darin, dass die einzelnen Residuen die Fehlersymptome in unterschiedlichen Wertebereichen darstellen. Dies hängt zum einen von der zugrundeliegenden Variablen (z. B. Steuersignal versus Temperaturwert) als auch von der beobachteten Fehlerart ab. Selbst wenn die Residuen auf einen einheitlichen Wertebereich (-1 bis 1) normiert sind, reagieren manche Variablen deutlich empfindlicher auf Fehler. Diese ungleiche Sensitivität erschwert es, die Fehlerauswirkung direkt anhand des Residuen-Werts zu bewerten, etwa durch den Vergleich der Betragssumme der Residuen mit einem Grenzwert.

Besonders herausfordernd ist der Umgang mit diskreten Variablen, wie Ein/Aus-Signalen, die nur die Werte 0 oder 1 annehmen. Eine falsche Schätzung kann unmittelbar zu hohen Residuen führen und die Falsch-positiv-Rate bei der Fehlererkennung erhöhen.

## 5. Darstellung und Analyse der Ergebnisse

Veranschaulicht werden die Herausforderungen der Residuen-Evaluieren in Abbildung 59. Dargestellt sind die zeitlichen Verläufe zweier Residuen (blau), die Betragssumme über alle Residuen (gelb,  $\sum |r|$ ) und der wahre Fehlerzustand (rot,  $FS_{wahr}$ ) für zwei ausgewählte Tage (RLT-Anlage AUD8, MSA-Gebäude). Der wahre Fehlerzustand ist das Ergebnis des in Abschnitt 3.6 vorgestellten Labeling-Methodik.




Abbildung 59: Zeitreihenbeispiele für ausgewählte Residuen (blau), die Betragssumme aller Residuen (gelb) und dem wahren Fehlerzustand (rot) für die RLT-Anlage AUD8 im MSA-Gebäude.

Am 15.06.2021 wird die Betragssumme wesentlich durch den Residuen-Wert für das Stellsignal der WRG ( $U_{WRG}$ ) bestimmt, verursacht durch eine Fehlfunktion der WRG. Dieser Fehler wirkt sich auch auf die Temperatur im Zuluftkanal nach der WRG ( $T_{ZUL,nWRG}$ ) aus. Allerdings liegen die Residuen in einem wesentlich kleineren Wertebereich. D.h. die Residuen sind in unterschiedlichen Wertebereichen sensitiv gegenüber dem observierten Fehler, was dazu führt, dass die Abweichung für die Schätzung  $T_{ZUL,nWRG}$  nahezu keinen Einfluss auf die Residuen-Summe hat.

Der zweite dargestellte Tag (17.06.2021) veranschaulicht den übermäßigen Einfluss diskreter Größen. Aufgrund einer fehlerhaften Klassifizierung für die Schätzung des

Stellsignals der adiabaten Kühlung ( $U_{ADK,pu}$ ) werden unmittelbar hohe Betragssummen  $\sum|r| > 1$  generiert. Die Folgen können falsch-positive FE-Ergebnisse aufgrund der fehlerhaften Klassifizierung einer einzelnen Schätzgröße sein.

Die Beispiele verdeutlichen, dass die alleinige Auswertung der Residuen-Beträge erhebliche Unsicherheiten in der Fehlererkennung mit sich bringt.

### 5.2.2. Residuen-Scoring und variables Toleranzband

Um die Herausforderungen in der Residuen-Evaluierung zu adressieren, wird ein Scoring mit einem variablen Toleranzband nach der in Abschnitt 3.4.2 beschriebenen Methodik eingeführt. Das Toleranzband wird dabei an die vom aktuellen Betriebsmodus abhängige Modellunsicherheit angepasst und individuell für jede Schätzgröße festgelegt. Zudem werden durch das Scoring die Residuen einheitlich gewichtet.

Abbildung 60 zeigt beispielhaft die Residuen-Histogramme für das Stellsignal der WRG ( $U_{WRG}$ ) der RLT-Anlage AUD8 im MSA-Gebäude, getrennt nach Betriebsmodi. Die zugrundeliegenden Daten stammen aus dem fehlerfreien Testzeitraum, wobei die vertikalen Linien den Median und die ermittelten Perzentil-Grenzen für das linearisierte Scoring markieren. Ein Heizbetrieb mit Umluftanteil tritt im Testzeitraum nicht auf.

Die Verteilungen der Residuen zeigen deutliche Unterschiede: Im Betrieb ohne Luftbehandlung und im Kühlbetrieb sind die Streuungen größer, was zu einem breiteren Toleranzband führt, definiert durch das obere und untere erste Perzentil ( $|p_1| > 0,34$ ). Im Heizbetrieb hingegen sind die Residuen überwiegend nahe Null, was auf eine geringere Modellunsicherheit und eine bessere Schätzgenauigkeit hindeutet. Dies liegt an der Betriebsweise im Heizmodus, bei der eine maximale WRG angestrebt wird, sodass das Stellsignal nach einer kurzen Anregelzeit meist den Wert 1 erreicht. Dadurch entstehen ein schmaleres Toleranzband und kleinere Perzentil-Werte für das Scoring. Eine Übersicht der Zahlen-Werte für die Perzentile  $p_1$  bis  $p_5$  gibt Tabelle 32 in Anhang A13.

## 5. Darstellung und Analyse der Ergebnisse




Abbildung 60: Residuen-Histogramme für das Stellsignal der WRG der RLT-Anlage AUD8 im MSA-Gebäude im fehlerfreien Betriebszustand getrennt nach dem aktuellen Betriebsmodus der Anlage. Die vertikalen Linien zeigen den Median und die Perzentile 1 bis 5 für das Scoring.

Abbildung 61 verdeutlicht, wie das Scoring das Potenzial der Fehlererkennung (FE) verbessert. Das dargestellte Beispiel entspricht der in Abschnitt 5.2.1 gewählten Situation, zur Erläuterung der Herausforderungen in der Residuen-Evaluierung (Abbildung 59). Am ersten Beispieltag (links) tritt eine Fehlfunktion der WRG auf, wodurch die Residuen sowohl für die Zulufttemperatur ( $T_{ZUL,nWRG}$ ) als auch für das Stellsignal der WRG ( $U_{WRG}$ ) den unteren Grenzwert (gestrichelte Linie,  $|p_1|$ ) überschreiten und im Tagesverlauf fast den maximalen Grenzwert (rote Linie,  $|p_5|$ ) erreichen. Dies führt zu einem starken Anstieg des Gesamt-Scores (gelb,  $\sum s$ ), mit einer Grenzwertüberschreitung (hier 1,5) der FE.




Abbildung 61: Zeitreihenbeispiele (15. und 17.06.2021) für ausgewählte Residuen (blau), die Summe aller Scores (gelb) und dem wahren Fehlerzustand (rot) für die RLT-Anlage AUD8 im MSA-Gebäude. Die gestrichelten und roten Linien in den Residuen-Diagrammen zeigen die untere und obere Grenze für das Scoring der Residuen.

Anders als bei einer direkten Auswertung der Residuen wird durch das Scoring am zweiten Beispieltag ein starker Anstieg der FE-Bewertungsgröße verhindert. Trotz hoher Residuen, die auf Modellunsicherheiten für das Pumpensignal der adiabaten Kühlung ( $U_{ADK, Pu}$ ) zurückzuführen sind, steigt der Gesamt-Score aufgrund der umgesetzten Evaluierungsmethodik nur geringfügig auf ca. 0,25. Folglich werden keine Fehlalarme getriggert.

Ein weiteres Beispiel für zeitlich variierende Grenzen im Scoring zeigt Abbildung 62. Dargestellt ist ein Sommertag mit temporär aktivierter adiabatischer Kühlung. Auf der linken Seite sind die Residuen sowie die Wertgrenzen für das Scoring zu sehen, während auf der rechten Seite die individuellen Scores, die Gesamtsumme aller ausgewerteten Residuen ( $\sum s$ ) und der wahre Fehlerzustand ( $FS_{wahr}$ ) abgebildet sind.

## 5. Darstellung und Analyse der Ergebnisse




Abbildung 62: Zeitreihenbeispiel (25.07.2022) für ausgewählte Residuen (blau) und Scores (grau), den Gesamtscore (gelb) und dem wahren Fehlerzustand (rot) der RLT-Anlage AUD8 im MSA-Gebäude. Die gestrichelten und roten Linien in den Residuen-Diagrammen zeigen die untere und obere Grenze für das Scoring der Residuen.

Um das adiabatische Kühlsystem mit Wasser zu befüllen, wird die Kühlfunktion vorübergehend deaktiviert. Dies führt zu einer stufenweisen Anpassung der Schwellenwerte, abhängig vom Betriebsmodus. Der gelabelte Fehler ( $FS_{wahr}$ ) kennzeichnet einen fehlgeschlagenen Versuch, das Kühlsystem mit Frischwasser zu befüllen, verursacht durch ein geschlossenes Ventil in der Frischwasserzuleitung. Infolgedessen kann keine Temperatursenkung der Ab- respektive Zuluft erfolgen.

Die Symptome des Fehlers zeigen sich in ansteigenden Residuen, insbesondere im Steuersignal des der WRG ( $U_{WRG}$ ) und der Umwälzpumpe des adiabatischen Kühlsystems ( $U_{ADK, Pu}$ ). Die individuellen Scores steigen daher, und der Gesamtscore ( $\sum S$ ) überschreitet den Schwellwert der Fehlererkennung (1,5). Der Fehler wird richtig erkannt.



Für den Rest des Tages arbeitet das Kühlsystem fehlerfrei. Aufgrund der wechselnden Temperaturniveaus während des Füllvorgangs schaltet sich die Wärmerückgewinnung vorübergehend ab, kehrt aber allmählich auf 100 % zurück. Dieses dynamische Betriebsverhalten führt in regelmäßigen Abständen zu kurzzeitigen Spitzen in den Residuen und damit einem Anstieg der Scores. Da der Grenzwert jedoch nur temporär überschritten wird, verhindert die implementierte FE-Logik (Abschnitt 3.4.3) das Auftreten von Fehlalarmen.

### 5.2.3. Grundschule Hohen Neuendorf

Für eine Performancebewertung (Abschnitt 3.7) wird die implementierte FE-Methodik (Abschnitt 3.4.3), ohne individuelle Anpassung der Perzentile für das Scoring der Residuen sowie des Grenzwertes von 1,5 für die Fehlererkennung auf Basis des Gesamtscores auf die untersuchten Fallstudien angewendet. Als Grundlage für das Modelltraining dienen die durch Fehlerlabels gefilterten Datensätze. Die Ergebnisse der evaluierten Metriken für die Grundschule Hohen Neuendorf (GSHN) zeigt Tabelle 21.

*Tabelle 21: Anteile fehlerhafter Betriebszustände in den Test-Datensätzen der RLT-Anlagen in der GSHN sowie die ermittelten Metriken der Fehlererkennung.*

	<b>FR</b>	<b>CR</b>	<b>MisCR</b>	<b>FAR</b>	<b>FDR</b>
<b>FLA</b>	1,7%	98,5%	1,5%	0,5%	40,4%
<b>FLB</b>	4,0%	96,8%	3,2%	1,9%	66,1%
<b>FLC</b>	0,2%	99,7%	0,3%	0,3%	84,2%
<b>FA</b>	2,0%	98,7%	1,3%	0,2%	66,4%
<b>AULA</b>	5,5%	93,8%	6,2%	1,3%	7,8%
<b>SPO</b>	0,5%	99,4%	0,6%	0,4%	56,7%

*FR: Fehlerrate, CR: Klassifizierungsrate, MisCR: Fehlklassifizierungsrate, FAR: Fehlalarmrate, FDR: Fehlererkennungsrate*

Der höchste Fehleranteil in den Betriebsdaten ( $FR = 5,5\%$ ) und die gleichzeitig geringste Fehlererkennungsrate ( $FDR = 7,8\%$ ) kann für die RLT-Anlage AULA beobachtet werden. Der Grund für die niedrige  $FDR$  ist ein invers operierendes Ventil für das Heizregister (HR). Dadurch kann das nominale Betriebsverhalten, insbesondere das Stellverhalten des Ventils, nicht ausreichend erlernt werden.

Deutlich bessere Ergebnisse werden mit Klassifizierungsraten ( $CR$ ) von über 96% für die übrigen Anlagen in der GSHN erzielt, wobei die individuelle  $FDR$  stark variiert und zwischen 40,4% und 84,2% liegt. Wesentliche Einflussfaktoren auf die  $FDR$  sind die Häufigkeit eines auftretenden Fehlertyps und dessen Fehlergröße. In der GSHN kann

## 5. Darstellung und Analyse der Ergebnisse

wiederkehrend eine Heizanforderung der RLT-Anlagen bei gleichzeitig abgeschalteter Wärmeversorgung beobachtet werden. Infolgedessen wird die Sollzulufttemperatur nicht erreicht. Tritt dieser Zustand nur kurzzeitig auf, oder ist die aktuelle Wärmeanforderung der Versorgungszone gering, ergeben sich kleine Residuen-Beträge, die von der entwickelten FE-Methodik durch das implementierte Toleranzband toleriert werden.

Der beschriebene Fehlertyp wird in Abbildung 62 anhand von Zeitreihenbeispielen für die RLT-Anlage FLA veranschaulicht. Im ersten Beispiel (links) wird durch die geringe Fehlergröße kein Alarm getriggert, während im zweiten Beispiel (rechts) durch die stärkere Auswirkung auf die Zulufttemperatur ein fehlerhafter Betrieb gemeldet wird.




Abbildung 63: Zeitreihenbeispiele für das Ergebnis der FE die Erkennung des Fehlertyps „keine Heizleistung bei geöffnetem HR-Ventil. (RLT-Anlage FLA).

Die Fehlalarmraten in der GSHN liegen, mit Ausnahme der RLT-Anlagen AULA (siehe oben) und FLB, auf einem sehr niedrigen Niveau unterhalb von 0,5%. Bei der Anlage FLB treten Fehlalarme häufig in kurzen Abständen während transients Betriebszustände auf, die durch wechselnde Betriebsmodi verursacht werden. Zum Beispiel schaltet die Anlage aufgrund der Stillstandstemperaturen in den Luftkanälen beim Einschalten kurzfristig in den WRG-Bypass-Modus, obwohl kurz darauf der Heizbetrieb aktiviert wird. Dies stellt zwar kein direktes fehlerhaftes Betriebsverhalten dar, zeigt jedoch Verbesserungspotenzial für die implementierte Regelstrategie (Abbildung 64, links). Auch bei seltenen Wetterereignissen können Fehlalarme in der GSHN beobach-

tet werden. Ein Beispiel zeigt Abbildung 64 (rechts). Durch einen Temperatursturz der Außenluft in der Tagesmitte innerhalb von 3h um 10 K kann in mehreren Variablen ein Anstieg der Residuen und im Gesamt-Score eine Überschreitung des FE-Grenzwertes beobachtet werden.




Abbildung 64: Zeitreihenbeispiele für Fehlalarme aufgrund transienter Zustände infolge wechselnder Betriebsmodi (links, RLT-Anlage FLB) und ungewöhnlicher Wetterereignisse (rechts, RLT-Anlage FA).

## 5. Darstellung und Analyse der Ergebnisse

---

### 5.2.4. Maison du Savoir

Die Klassifizierungsraten (CR) der Fehlererkennung (FE) für die RLT-Anlagen im Maison du Savoir (MSA) zeigen sehr unterschiedliche Leistungen (siehe Tabelle 22). Besonders bei Anlagen, deren Randbedingungen sich im Testzeitraum verändert haben, steigt der Anteil fehlerhafter Klassifizierungen (MisCR). Die individuellen Ursachen hierfür werden im Folgenden näher erläutert.

*Tabelle 22: Anteile fehlerhafter Betriebszustände in den Test-Datensätzen der RLT-Anlagen im Maison du Savoir sowie die ermittelten Metriken der Fehlererkennung.*

	<b>FR</b>	<b>CR</b>	<b>MisCR</b>	<b>FAR</b>	<b>FDR</b>
<b>AUD2</b>	84,4%	73,2%	26,8%	34,2%	74,5%
<b>AUD4</b>	1,7%	79,3%	20,7%	19,8%	26,5%
<b>AUD7</b>	19,0%	93,5%	6,5%	2,6%	79,9%
<b>AUD8</b>	6,0%	96,1%	3,9%	3,7%	93,6%
<b>AUD9</b>	6,5%	70,1%	29,9%	31,8%	96,8%
<b>AUD11</b>	50,1%	72,1%	27,9%	47,5%	91,5%

*FR: Fehlerrate, CR: Klassifizierungsrate, MisCR: Fehlklassifizierungsrate, FAR: Fehlalarmrate, FDR: Fehlererkennungsrate*

---

Der Betrieb der RLT-Anlage AUD2 im Auswertzeitraum ist durch eine Leckage des Heizregisterventils und einen damit verbundenen hohen Anteil fehlerhafter Zustände (FR) (84%) geprägt. Aus diesem Grund ist die hohe Fehlalarmrate (FAR) (34%) wesentlich auf die Berechnungsmethodik der FAR (siehe Abschnitt 3.7) zurückzuführen. Dieser Zusammenhang wird in der in Abbildung 65 dargestellten Konfusionmatrix der Klassifizierungsergebnisse veranschaulicht. Während die Farbgebung der Kacheln den Anteil an der wahren Klasse ( $FS_{wahr}$ ) darstellt, geben die Zahlenwerte den absoluten und relativen Anteil am gesamten Datensatz wieder. Da sich die FAR auf die wahre Fehlerklasse („kein Fehler“ = 0) bezieht, führt der geringe Anteil fehlerfreier Betriebszustände zu einer hohen FAR, obwohl der Anteil am Gesamtdatensatz mit 5,3% deutlich geringer ausfällt. Zudem ist häufig ein zeitlicher Versatz zwischen der Fehlererkennung und dem wahren Fehlerzustand zu beobachten, wodurch ein steigender Fehleranteil auch zu einer steigenden FAR führt.

Abhängig von der Fehlergröße werden diese Zustände zwar korrekt erkannt, jedoch wird die Fehlererkennungsrate (FDR = 75%) dadurch reduziert, dass im Trainings- und Validierungszeitraum kein Betrieb mit aktivierter Kühlung vorliegt. Dies verhindert die

Festlegung der Perzentil-Grenzen für das Scoring und folglich eine Auswertung des Fehlerzustandes im Kühlbetrieb.




Abbildung 65: Konfusions-Matrix für die Fehlererkennung im Testzeitraum der RLT-Anlage AUD2 im MSA-Gebäude. Angegeben sind die absoluten und relativen Anteile der Klassen am Gesamtdatensatz. Die Farbgebung der Kacheln zeigt den Anteil an der wahren Klasse ( $FS_{wahr}$ ).

Ein ebenfalls hoher Fehleranteil (50%) ist in den Datensätze der Anlage AUD11 zu beobachten. Ursache hierfür ist ein häufiges Einfrieren des Temperaturmesswertes für die Zuluft. Durch den hohen Fehleranteil wird die Verfügbarkeit fehlerfreier Betriebszustände zur Bestimmung der Perzentil-Grenzen für das Scoring stark eingeschränkt, was zu einem engeren Toleranzband und höheren FAR führt.

Für die RLT-Anlagen AUD4 und AUD9 zeichnen sich u.a. veränderte Sollwertvorgaben für hohe FAR verantwortlich. Während für AUD4 eine veränderte Raumsollwerttemperatur die FE-Performance im Heizbetrieb beeinträchtigt, führen in der FE für AUD9 eine veränderte Volumenstromregelung zu Fehlalarmen in allen Betriebszuständen.

Die Auswirkungen der angepassten Volumenstromregelung werden in Abbildung 66 links veranschaulicht. Dies führt nicht nur zu einem Anstieg der Residuen in der Schätzung des Stellsignals für den Zuluftventilator ( $U_{ZUL-ven}$ ), sondern auch in anderen Systemgrößen, wie beispielsweise dem Stellsignal der WRG ( $U_{WRG}$ ). In beiden Fällen sind die aus dem Trainings- und Validierungszeitraum ermittelten Wertegrenzen für das Scoring nicht mehr geeignet.

## 5. Darstellung und Analyse der Ergebnisse




Abbildung 66: Exemplarische Zeitreihen ausgewählter Residuen (blau), des Gesamtscores (gelb) sowie das Ergebnis der Fehlererkennung (rot, FD) und der wahren Fehlerzustand (rot,  $FS_{wahr}$ ). Das linke Diagramm zeigt Fehlalarme für Anlage AUD9 aufgrund von veränderten Soll-Volumenströmen, während das rechte Diagramm Fehlalarme aufgrund einer Überhitzung der Nutzungszone von AUD4 veranschaulicht,

Für alle RLT-Anlagen im MSA-Gebäude sind, mit unterschiedlich starker Ausprägung, Fehlalarme nach der sommerlichen Schließzeit des Gebäudes zu beobachten. Aufgrund einer langen Wärmeperiode und gleichzeitig abgeschalteter Kühlung sind die Versorgungszonen überhitzt. Begünstigt durch die hohe thermische Masse und eine nur während der Nutzungszeit aktivierte Kühlung dauert es mehrere Wochen, bis die sommerlichen Soll-Raumtemperaturen für den Kühlbetrieb wieder erreicht werden. Da die Konzeption der Anlagentechnik keine strikte Einhaltung dieser oberen Temperaturgrenze vorsieht, wird dieser Betriebszustand im Labeling-Prozess ( $FS_{wahr}$ ) nicht als fehlerhaft eingeordnet. Die Auswirkungen auf zwei ausgewählte Residuen und die FE für AUD4 zeigt das rechte Diagramm in Abbildung 66. Im gesamten Tagesverlauf liegen die Residuen sowohl für die Raumlufttemperatur als auch die Zuluft nach der WRG außerhalb des Toleranzbandes. Die Folge ist ein kontinuierlich hoher Gesamtscore mit einem positiven FD-Signal.

### 5.2.5. Anonymisierte Liegenschaft

Die RLT-Anlagen in der anonymisierten Liegenschaft (ISC) zeichnen sich durch einen weitestgehend fehlerfreien Betrieb aus (siehe Tabelle 23, FR). Der Betrieb der Anlagen mit wenigen transienten Zuständen ermöglicht eine präzise Schätzung des fehlerfreien Betriebes und ein gutes Erlernen der Wertegrenzen für das Scoring. Das Ergebnis sind hohe Klassifizierungsraten über 98% und sehr niedrige Fehlalarmraten (FAR) unter 0.5%. Die selten auftretenden Fehlalarme werden beobachtet, wenn die Anlagen innerhalb eines kurzen Zeitraums (30 Minuten) sequenziell in mehrere Betriebsmodi wechseln. Aufgrund des groben Aufzeichnungsintervalls von 10 Minuten können in solchen Fällen vorübergehend unplausible Wertekombinationen auftreten. Mit einem etwas höheren FAR von 1,1% stellt die Anlage CTA17 eine Ausnahme dar. Diese Fehlalarme werden meist durch im Vergleich zum Test- und Validierungszeitraum temporär höhere Volumenströme verursacht. Dies deutet auf eine intensivere Nutzung der Versorgungszone hin und erfordert ein erneutes Training der Wertgrenzen für das Scoring.

*Tabelle 23: Anteile fehlerhafter Betriebszustände in den Test-Datensätzen der RLT-Anlagen in der anonymisierten Liegenschaft sowie die ermittelten Metriken der Fehlererkennung.*

	<b>FR</b>	<b>CR</b>	<b>MisCR</b>	<b>FAR</b>	<b>FDR</b>
<b>CTA01</b>	<0,1%	99,8%	0,2%	0,1%	62,5%
<b>CTA02</b>	<0,1%	99,8%	0,2%	0,1%	25,0%
<b>CTA03</b>	<0,1%	99,7%	0,3%	0,2%	30,0%
<b>CTA08</b>	2,3%	98,1%	1,9%	0,4%	31,8%
<b>CTA17</b>	0,5%	98,9%	1,1%	1,0%	84,4%

*FR: Fehlerrate, CR: Klassifizierungsrate, MisCR: Fehlklassifizierungsrate, FAR: Fehlalarmrate, FDR: Fehlererkennungsrate*

Die Fehlerkennungsrate (FDR) sind mit z.T. ca. 30% sehr niedrig, was jedoch auf den geringen Fehleranteil und die nicht vollständig überlappenden Zeiträume der Fehlererkennung (FE) und der gesetzten Labels zurückgeführt werden kann.

Einen etwas höheren Fehleranteil hat mit 2,3% die RLT-Anlage CTA08. Im Betrieb ist wiederholt festzustellen, dass die Pumpe im hydraulischen Kreislauf des Heizregisters nicht immer einschaltet, wenn das Ventil öffnet. Dieser Fehler wird durch die FE-Methodik erkannt, jedoch nur dann, wenn der Betrieb ausreichend stark beeinflusst wird. Abbildung 67 zeigt einen exemplarischen Tagesverlauf. In den Zeiträumen des Fehlers ( $F_{wahr}$ ) steigen die Residuen für die Stellsignale der Pumpe ( $U_{HR,Pu}$ ) und des

## 5. Darstellung und Analyse der Ergebnisse

Ventils ( $U_{HR,Ventil}$ ). Bei einer geringen Ventilöffnung (12:15 bis 13:15) wird der FE-Grenzwert für den Gesamtscore nicht erreicht. Nur wenn das Ventil stärker öffnet (16:00 bis 17:00), wird der Grenzwert überschritten und ein Alarm ausgelöst.

Zudem zeigt sich bei dieser Anlage, dass der Umgang mit selten auftretenden Betriebsmodi herausfordernd ist. Etwa sechsmal jährlich werden Abzugshauben der Laboreinrichtungen als Teil des Lüftungssystems eingeschaltet, wodurch die Betriebscharakteristik verändert und Fehlalarme ausgelöst werden.




Abbildung 67: Exemplarische Zeitreihen ausgewählter Residuen (blau), des Gesamtscores (gelb) sowie das Ergebnis der Fehlererkennung (rot,  $FD$ ) und der wahre Fehlerzustand (rot,  $F_{wahr}$ ) für die RLT-Anlage CTA08 (ISC-Gebäude). Der wahre Fehlerzustand signalisiert eine Ventilöffnung bei abgeschalteter Pumpe im hydraulischen Kreis des Heizregisters.

### 5.2.6. Veränderung zu einer $L_2$ -Norm basierten Fehlererkennung

Die implementierte Scoring-Methode zur Residuen-Evaluierung zielt darauf ab, die Qualität der Fehlererkennung (FE) zu erhöhen. Dazu zählen nicht nur eine Verringerung der Fehlalarmrate (FAR) und eine Steigerung der Fehlererkennungsrate (FDR), sondern auch die Erkennung von unterschiedlichsten Fehlertypen und die Vermeidung von Alarmen bei einer geringen Fehlergröße (Anzahl der Alarme). Um die Veränderung zu quantifizieren, werden die Ergebnisse der Scoring-Methode der  $L_2$ -Norm-Methode (siehe Abschnitt 3.4.1) gegenübergestellt.

Für den Vergleich wird die Sensitivität der  $L_2$ -Norm-Methode über den Skalierungsfaktor ( $f$ ) zur Berechnung des FE-Grenzwertes individuell für jede RLT-Anlage manuell



angepasst (siehe Tabelle 33 in Anhang A16), sodass möglichst ähnliche FDR erzielt werden. Vom Vergleich ausgenommen sind RLT-Anlagen, deren Betrieb im Auswertzeitraum dauerhaft fehlerhaft sind (z.B. Leckage des Heizregisterventils) oder deren Betriebscharakteristik sich im Testzeitraum derartig verändert hat, dass keine zuverlässige FE möglich ist. Beide Situationen erfordern eine Aktualisierung der Modelle mit neuen fehlerfreien Betriebsdaten und sind daher nicht repräsentativ für den Anwendungsfall. Zu diesen Anlagen zählen AULA (GSHN), AUD2, AUD9 und AUD11 (MSA).

Die resultierenden Fehlalarmraten (links) und die Anzahl der Alarme (rechts) für beide Methoden sind in Abbildung 68 dargestellt. Ergänzend wird die Anzahl der Alarme für den gelabelten Fehlerzustand (FS-Label) gezeigt. Neben den individuellen Ergebnissen für die RLT-Anlagen (unten) zeigen die Diagramme den Median und dessen Vertrauensintervall<sup>21</sup> (95%) aller Anlagen (oben).

Der Median für die FAR verbessert sich durch die Scoring-Methode deutlich von 0,8% auf 0,5% bei gleichzeitiger Verkleinerung des Vertrauensintervalls. Allerdings wird die FAR nicht für alle RLT-Anlagen sichtbar reduziert. In einzelnen Fällen kann sogar ein signifikanter Anstieg beobachtet werden. Hierzu zählen die RLT-Anlagen FLB, AUD4, AUD7 und AUD8. Im Gegensatz zur L2-Norm basierten FE werden in der Scoring-Methode die Residuen diskreter Größen, abhängig von den gefundenen Grenzen für das Scoring, nicht im vollen Umfang in der grenzwertbasierten FE berücksichtigt. Dadurch ist es erforderlich, dass mindestens ein weiterer Residuen-Wert das Toleranzband verlässt, um einen Alarm auszulösen (siehe Beispiel Abb. 66). Auf diese Weise werden Alarme bei geringer Fehlerwirkung vermieden.

Tritt jedoch in der beobachteten Anlage häufig ein Fehlertyp auf, der seine Symptome in einer diskreten Größe zeigt, führt dieses Verhalten im Vergleich zur L2-Norm-basierten FE zu einer Abnahme der FDR. In dem hier durchgeführten Vergleich kann dadurch die Sensitivität der L2-Norm-Methode bei gleicher FDR stark verringert werden (hoher Skalierungsfaktor). Die Folge sind deutlich niedrigere FAR für den ausgewerteten Testzeitraum. In der weiteren Anwendung kann ein hoher Grenzwert (= geringe Sensitivität) jedoch dazu führen, dass Fehlertypen, die ihre Symptome vorrangig in kontinuierlichen Größen ausdrücken, nicht erkannt werden.

---

<sup>21</sup> Das Vertrauensintervall zeigt den Bereich an, in dem der wahre Wert mit einer Wahrscheinlichkeit von 95% liegt. Größere Intervalle deuten auf eine höhere Unsicherheit hin.

## 5. Darstellung und Analyse der Ergebnisse




Abbildung 68: Fehlalarmrate (links) und Anzahl der Alarme (rechts) für die Fehlererkennung basierend auf der L2-Norm (blau) und der Scoring-Methode (rot). Ergänzt ist die Anzahl der Alarme für den gelabelten Fehlerzustand (FS-Label, grau) dargestellt. Neben den individuellen Ergebnissen für die RLT-Anlagen (unten) zeigen die Diagramme den Median und dessen Vertrauensintervall (95%) (oben).

Dieser wesentliche Unterschied der beiden Ansätze schlägt sich auch in den Ergebnissen der RLT-Anlage AUD4 nieder. Aufgrund der Sollwertveränderung für die Raumlufttemperatur sind für beide Ansätze große FAR (>8%) zu beobachten. Jedoch liegt die FAR der Scoring-Methode mit fast 20% deutlich höher. Hier führt das Scoring zu einer stärkeren Gewichtung der Raumlufttemperatur-Residuen im Heizbetrieb und damit einer höheren FAR. Auch wenn es sich hier um eine Sollwertveränderung und nicht um einen fehlerhaften Betrieb handelt, zeigt dieses Beispiel, dass die Scoring-Methode besser in der Lage ist, Anomalien zu erkennen, die sich vorrangig in kontinuierlichen Variablen ausprägen.

Kohärent zu den FAR verändert sich auch die Anzahl der Alarme (rechtes Diagramm in Abbildung 68). Betrachtet man jedoch die individuellen Ergebnisse, wird deutlich, dass die Anzahl der Alarme nicht immer im gleichen Maße ansteigt wie die FAR. Deutlich zu erkennen ist dieser Effekt für die RLT-Anlagen AUD4, AUD7 und AUD8. Für die RLT-Anlage ist AUD4 sogar eine Umkehrung zu beobachten. Trotz einer im Vergleich

zur L2-Norm-Methode höheren FAR, werden durch die Scoring-Methode weniger Alarme verursacht. Hieraus lässt sich ableiten, dass die hohe Fehlalarmrate vorrangig durch kontinuierlich auftretende Alarme verursacht wird. Betrachtet man alle Anlagen, sinkt der Median für die Anzahl Alarme im Testzeitraum von 27 auf 20 Alarme.

Die Ergebnisse zeigen, dass durch die Scoring-Methode sowohl die FAR als auch die Anzahl der Alarme im Vergleich zur L2-Norm-Methode für die Mehrheit der untersuchten Fallstudien gesenkt werden können und die Sensitivität gegenüber Fehlertypen, deren Symptome sich in kontinuierlichen Größen ausprägen, gesteigert wird.

### 5.2.7. Vergleich mit einem Experten-System

Im Rahmen des Labeling-Prozesses wurden die Betriebsdaten von insgesamt 11 RLT-Anlagen der Fallstudien mit einem vom Fraunhofer ISE entwickelten Expertensystem basierend auf Regeln analysiert (siehe Abschnitt 3.6). Abhängig von den verfügbaren Datenpunkten des Systems werden die Regeln automatisiert angewendet. Da es sich beim Expertensystem methodisch und charakteristisch um einen anderen Ansatz als beim Residuen-generierenden Ansatz handelt, ist ein direkter Vergleich schwierig, zumal die Ergebnisse des Experten-Systems durch das Filtern fehlerhafter Betriebszustände in den Trainingsdaten indirekt in die Modellbildung des Residuen-generierenden Ansatzes einfließen. Eine Analyse der Unterschiede kann jedoch die Vor- und Nachteile einer einzelnen oder kombinierten Anwendung aufzeigen.

In der regelbasierten FE werden die Grenzwerte individuell an das Betriebsverhalten des observierten Systems angepasst. Zudem werden nur die Ergebnisse von Regeln für die Generierung eines globalen Fehlersignals berücksichtigt, die im Einklang mit der umgesetzten Regelstrategie der observierten Anlage sind und deren Ergebnisse im Labeling-Prozess als richtig eingestuft werden. Das Expertensystem enthält beispielsweise Regeln, die einen asynchronen Betrieb der Ventilatoren erkennen. Bei Anlagen mit Umluftbetrieb ist dieser Betriebszustand jedoch systembedingt vorhanden, sodass eine solche Anwendung für die FE ungeeignet ist.

Die individuelle Parametrisierung des Expertensystems ermöglicht eine Anwendung ohne Fehlalarme, erfordert jedoch ein fundiertes Verständnis des Systemverhaltens und einen erhöhten initialen Zeitaufwand für die Implementierung. Ein Vorteil der regelbasierten Fehlererkennung ist, dass keine Trainingsdaten benötigt werden und auch Fehler im ausgeschalteten Zustand erkannt werden können. Dazu zählen beispielsweise eine fehlerhafte Stellung der Außenluftklappen oder eine dauerhaft einge-

## 5. Darstellung und Analyse der Ergebnisse

schaltete Pumpe im hydraulischen Kreislauf des Heizregisters. Darüber hinaus liefern die getriggerten Regeln Hinweise für die Fehlerisolation.

Abbildung 69 zeigt die resultierenden Fehlererkennungsraten (FDR) im Testzeitraum für das Expertensystem und den Residuen-generierenden Ansatz mit einer Scoring-basierten Residuen-Evaluierung. Für den Vergleich werden die Signale der FE und des tatsächlichen Fehlerzustandes (FS) identisch aufbereitet. Hierzu zählt insbesondere das Filtern kurzzeitiger positiver Werte (siehe Formel (20) in Abschnitt 3.4.3). Zudem erfolgt eine Auswertung ausschließlich im eingeschalteten Zustand. In Abbildung 69 nicht berücksichtigt sind die RLT-Anlagen AUD9 und AUD11. Bedingt durch veränderte Randbedingungen und resultierend sehr hohen FAR (>30%) ist ein Ergebnisvergleich dieser Anlagen nicht zweckmäßig.




Abbildung 69: Fehlererkennungsrate (blau) für die Scoring-Methode (rot) und das Expertensystem (blau). Neben den individuellen Ergebnissen für die RLT-Anlagen (unten) zeigt das Diagramm den Median und das Vertrauensintervall (95%) (oben).

Während der Residuen-generierende Ansatz in der Lage ist unbekannte Fehler zu identifizieren, erkennt eine regelbasierte FE ausschließlich Fehler, deren Symptome durch eine zuvor definierte Regel erfasst werden. Diese Eigenschaft zeigt sich auch in

den Ergebnissen der FDR. Für alle observierten RLT-Anlagen erzielt der Residuen-generierende Ansatz höhere FDR. Während das Experten-System ein Median von 13% erzielt, erreicht der Residuen-generierende Ansatz ein Median von 70% für die FDR. Hierbei ist jedoch zu beachten, dass der Residuen-generierende Ansatz, im Gegensatz zum Expertensystem, auch Fehlalarme erzeugt (siehe Abschnitte 5.2.3 bis 5.2.5) und Zeiträume im ausgeschalteten Zustand nicht analysiert.

In der FE für die RLT-Anlagen im GSHN-Gebäude (FLA, FLB, SPO), kann ein wesentlicher Unterschied in der Identifizierung des Betriebszustandes „Heizanforderung bei abgeschalteter zentraler Wärmeversorgung“ beobachtet werden. Im Expertensystem wird dieser Zustand nur indirekt durch die Überprüfung der Temperaturgrenzen für Zu- und Abluft erkannt. Der Residuen-generierende Ansatz wertet hingegen die Abhängigkeiten aller Systemgrößen aus und reagiert dadurch deutlich sensibler auf den genannten Fehlertyp.




Abbildung 70: Exemplarische Zeitreihen für observierte Betriebsfehler und die Ergebnisse der FE. Das linke Beispiel zeigt eine Leckage des Heizregisterventils für die RLT-Anlage FLB in der GSHN, die ausschließlich durch den Residuen-generierenden Ansatz erkannt wird. Ein mit dem Expertensystem übereinstimmendes Ergebnis zeigt das rechte Diagramm (CTA17, ISC-Gebäude). Obwohl das Betriebssignal einen abgeschalteten Abluftventilator suggeriert und die Außenluftklappen geschlossen sind, ist ein deutlicher Überdruck zu verzeichnen.

## 5. Darstellung und Analyse der Ergebnisse

---

Weiterhin werden durch den Residuen-Generierenden Ansatz auch Fehler erkannt, die die Regeln nicht erfassen. Ein Beispiel hierfür ist eine Ventil-Leckage in der Anlage FLB, die im Zeitreihendiagramm in Abbildung 70 (links) dargestellt ist. Obwohl das Heizregisterventil scheinbar geschlossen ist, kann im hydraulischen Kreislauf ein stetiger Volumenstrom beobachtet werden. Hierdurch wird der Zuluft kontinuierlich Wärme zugeführt, und die Anlage muss trotz niedriger Außenlufttemperaturen den Bypass der WRG öffnen, um die Sollwertvorgaben für die Zulufttemperatur einzuhalten.

Eine manuelle oder regelbasierte Erkennung dieses Fehlers ist bei dieser Anlage nur möglich, wenn der Volumenstrom im hydraulischen Kreislauf einbezogen wird. Dieser Messwert ist jedoch nicht Bestandteil der standardmäßig im System installierten Sensorik und wurde lediglich durch das Intensivmonitoring im Rahmen eines Forschungsprojektes separat erfasst. Vor diesem Hintergrund wurde die automatisierte Fehlererkennung (FE) ohne Berücksichtigung des Volumenstroms im hydraulischen Kreislauf durchgeführt.

Dieses Beispiel verdeutlicht einen wesentlichen Vorteil des Residuen-generierenden Ansatzes: Durch die Modellierung des Systemverhaltens kann auch bei einer geringen Anzahl verfügbarer Datenpunkte eine große Anzahl verschiedener Fehlertypen erkannt werden.

Eine Ventil-Leckage kann auch im Betrieb einer weiteren RLT-Anlage (AUD2, MSA-Gebäude) beobachtet werden. Im Gegensatz zum vorherigen Beispiel (FLB, GSHN) wird der Fehler hier durch das Expertensystem erkannt. Dank einer größeren Anzahl an Sensoren im System ist es möglich, eine Regel zu formulieren, die die Temperaturdifferenz über das Heizregister im Zuluftstrom analysiert und mit der Ventilstellung sowie dem Ventilatorstatus abgleicht. Diese Regel war ursprünglich nicht implementiert und konnte auf Grundlage der Beobachtungen ergänzt werden.

Die allgemein höheren FDR des Residuen-generierenden Ansatzes lassen sich hauptsächlich auf die Präsenz von Fehlertypen zurückführen, für deren Erkennung im Expertensystem keine Regeln definiert sind oder aufgrund der Datenverfügbarkeit keine Regeln definiert werden können. Fehlerhafte Betriebszustände, die einen großen Einfluss auf die FDR der beobachteten Anlagen haben, sind:

- Eingeschalteter Betriebszustand ohne messbaren Luftvolumenstrom (AUD7)
- Fehlerhaftes Pumpensignal der adiabaten Kühlung (AUD7)

- Keine Frischwasserzufuhr zur Befüllung des adiabaten Kühlsystems (AUD8, siehe Abbildung 61 in Abschnitt 5.2.2)
- Abgeschaltete WRG trotz Unterschreitung der Soll-Zulufttemperatur (CTA02)
- Fehlerhaftes Pumpensignal des Heizregisters (CTA08)
- Heizanforderung bei abgeschalteter Wärmeversorgung (CTA17)

Fehler, die durch das Expertensystem erkannt werden, führen auch im Residuen-generierenden Ansatz zu einem positiven Fehlersignal. Ein Beispiel hierfür ist in Abbildung 70 (rechts) dargestellt. Obwohl das Betriebssignal einen abgeschalteten Abluftventilator suggeriert und die Außenluftklappen geschlossen sind, ist ein deutlicher Überdruck im Abluftkanal festzustellen. Der Fehler wird durch beide Systeme erkannt. Da im Residuen-generierenden Ansatz ein gleitendes Zeitfenster ausgewertet wird, wird jedoch ein Fehlersignal generiert, das über den eigentlichen Fehlerzeitraum hinaus anhält.

Zusammenfassend zeigt diese Auswertung, dass der Residuen-generierende Ansatz im Vergleich zum Expertensystem ein sensitiveres Verhalten gegenüber fehlerhaften Betriebszuständen aufweist und dadurch deutlich höhere Fehlererkennungs-raten erzielt. Zudem können Fehler erkannt werden, für deren regelbasierte Erkennung die notwendigen Datenpunkte fehlen oder keine Regeln definiert wurden. Durch die höhere Empfindlichkeit können im Vergleich zum Expertensystem höhere Fehlalarmraten entstehen.

### 5.2.8. Zusammenfassung und Diskussion

Die in dieser Arbeit entwickelte Methode zur Residuen-Evaluierung adressiert die Herausforderungen in der Fehlererkennung und -diagnose gebäudetechnischer Systeme (Abschnitt 5.2.1). Im Rahmen der Fehlererkennung (FE) besteht die Hauptaufgabe der Evaluierung darin, die ausgewerteten Größen robust gegenüber Fehlalarmen zu gestalten und gleichzeitig sensibel auf tatsächliche Fehler zu reagieren.

Dazu wurde in dieser Arbeit ein variables Toleranzband eingeführt, das die Modellunsicherheiten bei der Schätzung des nominalen Verhaltens berücksichtigt. Gleichzeitig normiert ein Scoring die Residuen in den fehleranfälligen Bereichen. Dies ermöglicht die Berechnung eines aussagekräftigen Gesamtscores für eine grenzwertbasierte Fehlererkennung (Abschnitt 5.2.2).

In der Anwendung der FE-Methodik auf insgesamt 17 Fallstudien zeigen sich, abhängig vom Gebäude und der observierten Anlage, sehr unterschiedliche Performance-

## 5. Darstellung und Analyse der Ergebnisse

Metriken. Auf Gebäudeebene ist die Fehlalarmrate (FAR) (siehe Abbildung 71) für das Maison du Savoir (MSA) mit einem Median von 25,8% signifikant höher als für die Grundschule Hohen Neuendorf (GSHN) (0,6%) und die anonymisierte Liegenschaft (ISC) (0,2%). Dies ist vor allem auf die Vielzahl an transienten Betriebszuständen zurückzuführen, die durch eine komplexe Regelstrategie mit zahlreichen Ausnahmebedingungen verursacht werden. Zudem ist der Anteil fehlerhafter Betriebszustände in den Datensätzen dieses Gebäudes deutlich höher, und der kurze Testzeitraum (3 Monate) enthält eine anhaltende Wärmeperiode mit einer Überhitzung der Versorgungszonen, die durch den Residuen-generierenden Ansatz als fehlerhaft eingestuft wird. Dies zeigt, dass ein statistischer FE-Ansatz nur bedingt zwischen Fehlerzuständen und seltenen, aber regulären Betriebszuständen unterscheiden kann.




Abbildung 71: Median der Fehlalarmrate (FAR, links) und der Fehlererkennungsrate (FDR, rechts), gruppiert nach Gebäude der untersuchten Fallstudien.

Zusammenfassend lassen sich anhand der Fallstudien folgende Ursachen für Fehlalarme identifizieren (Abschnitte 5.2.3 bis 5.2.5):

- extreme Wettersituationen, die zu ungewöhnlichen Betriebsverhalten führen
- langanhaltende transiente Zustände, z. B. durch einen wiederholten Wechsel des Betriebsmodus im Bereich des Aufzeichnungsintervalls der Betriebsdaten
- veränderte Randbedingungen (z.B. eine veränderte Vorlauftemperatur in der zentralen Wärmeversorgung) oder Sollwertvorgaben in der Anwendungsphase
- selten auftretende Betriebsmodi, für die keine spezifischen Perzentil-Grenzen definiert wurden (z. B. Wartungsmodus oder aktivierte Abzugshauben in Laboreinrichtungen)
- und dauerhaft vorliegende Fehlerzustände (z.B. Ventil-Leckage), die eine zuverlässige Bestimmung der Perzentil-Grenzen verhindern (kleines Toleranzband).



Um einen direkten Vergleich der Ergebnisse zu ermöglichen, wurden in dieser Arbeit die Parameter für die FE bei allen analysierten RLT-Anlagen einheitlich gewählt. In der praktischen Anwendung können jedoch individuelle Anpassungen zur Reduzierung der FAR durchgeführt werden. Beispielsweise können kurzzeitige Fehlalarme, die durch transiente Betriebszustände verursacht werden, durch eine längere Mindestdauer eines Fehlersignals vermieden werden. Bei extremen Wettersituationen, veränderten Randbedingungen oder Sollwertvorgaben ist hingegen ein erneutes Erlernen der Perzentil-Werte für das Scoring ein sinnvoller Ansatz. Sind ausreichend Daten für das neue Betriebsverhalten vorhanden, sollte das Training der Modelle zur Schätzung des nominalen Verhaltens mit einem erweiterten Datensatz wiederholt werden.

Die Anzahl der Fehlalarme lässt sich zudem durch eine Anpassung der Sensitivität über den Grenzwert  $J_{th,s}$  verringern. Allerdings besteht hierbei die Gefahr, dass die FE-Performance beeinträchtigt wird. Der Einfluss von  $J_{th,s}$  sollte daher in zukünftigen Studien weiter untersucht werden, um einen robusten Standardwert zu definieren und Orientierungshilfen für die Anwendung zu formulieren.

Hinsichtlich der Erkennung von Fehlern zeigt der verfolgte Ansatz in allen Fallstudien eine hohe Sensitivität. Sowohl für die GSHN als auch das MSA liegt der Median der Fehlererkennungsrate (FDR) mit 61,4% und 82,9% auf einem hohen Niveau (siehe Abbildung 71). Die deutlich niedrigere FDR für das ISC-Gebäude mit einem Median von 31,8% lässt sich hauptsächlich auf den weitestgehend fehlerfreien Betrieb der RLT-Anlagen zurückführen. Die Nichterkennung eines einzelnen Fehlers führt hier zu einer starken Abnahme der FDR.

Aus den untersuchten Fallstudien können folgende Ursachen für die Nichterkennung von Fehlern identifiziert werden (Abschnitte 5.2.3 bis 5.2.5):

- Das Systemverhalten wird durch den vorliegenden Fehler nur geringfügig beeinträchtigt (kleine Fehlergröße).
- Die Trainingsdaten enthalten fehlerhafte Betriebszustände, wodurch hohe Perzentil-Werte für das Toleranzband und das Scoring bestimmt werden (hohe Toleranz).
- Es liegt ein dauerhaftes Fehlverhalten vor (z.B. inverses Verhalten des Heizregisterventils), sodass die fehlerfreie Datenmenge unzureichend ist, um geeignete Perzentil-Werte für das Scoring zu finden (hohe Toleranz).
- Ein in der Anwendungsphase beobachteter Betriebsmodus ist nicht in den Trainings- und Validierungsdaten enthalten (z.B. Heizbetrieb mit Umluftanteil,

## 5. Darstellung und Analyse der Ergebnisse

---

AUD8). Dadurch kann für den betreffenden Betriebsmodus kein Scoring durchgeführt werden.

Auch wenn die Nichterkennung von Fehlern mit geringer Fehlergröße numerisch zu einer Abnahme der FE-Performance führt, kann diese Eigenschaft im Bereich der technischen Gebäudeausrüstung als positiv eingeordnet werden. Hierdurch werden unbedeutende Fehlerzustände ignoriert, die Anzahl der Alarme reduziert und die Akzeptanz des FE-Systems erhöht.

Die umgesetzte Scoring-Methode ermittelt das Toleranzband sowie die Stützwerte für das Scoring separat für verschiedene Betriebsmodi. Im Entwicklungsprozess der Methodik konnten anhand der Fallstudien insgesamt sechs Betriebsmodi mit stark variierenden Modellunsicherheiten identifiziert werden. In der Weiterentwicklung können zusätzliche Betriebsmodi für RLT-Anlagen definiert und das Scoring weiter verfeinert werden. Beispielsweise kann eine differenziertere Auswertung der WRG von RLT-Anlagen mit Wärmerückgewinnungsrad im Teil- und Volllastbetrieb die Performance weiter verbessern.

Im Vergleich zur L2-Norm des Residuen-Vektors kann durch die Scoring-Methode sowohl die FAR als auch die Anzahl der Alarme gesenkt und die Sensitivität gegenüber Fehlertypen, die sich in kontinuierlichen Größen äußern, deutlich gesteigert werden (siehe Abschnitt 5.2.6). Fehlalarme aufgrund einer fehlerhaften Schätzung diskreter Systemgrößen können effektiv verhindert werden. Ein weiterer wesentlicher Vorteil zeigt sich im geringeren Parametrisierungsaufwand: Während die Scoring-Methode mit Standard-Parametern zuverlässige Ergebnisse liefert, muss in der L2-Norm-Methode der Schwellwert für die FE individuell in einem großen Wertebereich festgelegt werden.

Der Vergleich mit einem Expertensystem zeigt (Abschnitt 5.2.7), dass die FDR durch den Residuen-generierenden Ansatz deutlich gesteigert werden kann. Für die untersuchten Fallstudien steigt der Median von 13% auf 70%. Neben der höheren Sensitivität des Residuen-generierenden Ansatzes liegt der Hauptvorteil darin, dass Fehler erkannt werden, für die im Expertensystem keine Regeln definiert sind oder aufgrund fehlender Daten keine Regeln angewendet werden können. Zudem steigt der Parametrisierungsaufwand mit der Anzahl Regeln, wohingegen in der Scoring-Methode die Parameter automatisiert ermittelt werden und lediglich ein finaler Grenzwert angepasst werden muss. Allerdings muss berücksichtigt werden, dass der Residuen-generierende Ansatz durch seine höhere Sensitivität Fehlalarme erzeugt und dass die Ergebnisse des Expertensystems indirekt durch das Filtern fehlerhafter Betriebszu-

stände in den Trainingsdaten in die Modellbildung des Residuen-generierenden Ansatzes einfließen.

### 5.3. Fehlerisolation

In der Fehlerisolation wird das fehlerhafte Betriebsverhalten einem Fehlertyp zugeordnet. Sie ist damit ein wesentlicher Teilschritt der Fehlerdiagnose und bildet die Grundlage für die Fehleridentifikation (Größe, zeitliches Verhalten, etc.) und der nachgelagerten Fehlerevaluierung (Kosten, Energie, Komfort, etc). Mit dem Ziel einen möglichst datengetriebenen FED-Prozess mit geringem Parametrisierungsaufwand zu entwickeln, wird in diesem Abschnitt das Potential von ML-Modellen zur Fehlerisolation auf Basis der berechneten Residuen untersucht. Hierzu werden zunächst die, in den Fallstudien observierten, Fehlertypen und deren Anteile in den Datensätzen ausgewertet (Abschnitt 5.3.1), bevor die resultierenden Fehlermuster veranschaulicht und Fallstudienübergreifend verglichen werden (Abschnitt 5.3.2). Anschließend wird geprüft, ob die Fehlermuster durch einen ML-Ansatz isoliert werden können (Abschnitt 5.3.3) und die Ergebnisse diskutiert (Abschnitt 5.3.4).

#### 5.3.1. Observierte Fehlertypen in den Fallstudien

Im Rahmen des Labeling-Prozesses (Abschnitt 3.6) wurden die Zeiträume der beobachteten Fehlertypen mit eindeutigen Identifikatoren versehen, um eine differenzierte Auswertung zu ermöglichen.

Den Identifikatoren sind kurze Beschreibungen der Fehlertypen zugeordnet, wie etwa „Keine Heizleistung bei geöffnetem Heizregister- (HR-) Ventil“. Es handelt sich dabei jedoch nicht um die konkreten Fehlerquellen. Dies verdeutlicht eine grundsätzliche Grenze in der Fehlerdiagnose von HKL-Systemen. Im genannten Beispiel lässt sich zwar feststellen, dass keine Erwärmung der Zuluft stattfindet, jedoch kann aufgrund der verfügbaren Daten die genaue Ursache nicht eindeutig bestimmt werden. Neben einer fehlenden Wärmeversorgung könnte das Verhalten auch durch ein feststehendes HR-Ventil verursacht werden. Letzteres ließe sich durch eine Betriebsrückmeldung über die tatsächliche Ventilposition erkennen, allerdings wird diese Information in der Praxis nur selten erfasst. Die Aufgabe der Fehlerisolation besteht daher darin, die Fehlersymptome so genau wie möglich zu identifizieren, um die potenziellen Fehlerquellen bestmöglich einzugrenzen.

Die im Betrieb der RLT-Anlagen gefundenen Fehlertypen und deren Anteile an den fehlerbehafteten Datensätzen sind in Tabelle 24 bis Tabelle 26 gelistet. Die Anteile

## 5. Darstellung und Analyse der Ergebnisse

sind auf den gesamten Betrachtungszeitraum, bestehend aus Trainings-, Validierungs- und Testzeitraum, bezogen. Da manche Fehlerquellen sich in mehreren der beschriebenen Fehlertypen niederschlagen, kann die Gesamtsumme der Teilmengen auch einen Betrag über 100% annehmen. Beispielsweise ist eine zu niedrige Temperatur der Zuluft möglicherweise, aber nicht kausal, eine Folge einer fehlenden Heizleistung bei einem offenen HR-Ventil. Eine doppelte Zuordnung eines Fehlverhaltens zu mehreren Typen ist daher möglich und resultiert wesentlich durch den Einsatz von Regeln zur Automatisierung des Labeling-Prozesses. Bei fehlender Angabe eines Prozentwertes, kann der gelistete Fehlertyp im Betrieb der betreffenden Anlage nicht observiert werden.

Tabelle 24: Observierte Fehlertypen und deren Anteile an den fehlerbehafteten Daten der Fallstudien im GSHN-Gebäude.

	FLA	FLB	FLC	FA	AULA	SPO
Fehleranteil der Daten	8,4%	4,5%	0,2%	3,8%	7,8%	1,4%
Asynchroner Betrieb der Ventilatoren	0%	0%	0%	0%	1%	
Keine Heizleistung bei geöffnetem HR-Ventil	100%	68%	100%	100%	23%	98%
Gleichzeitiges Heizen und adiabates Kühlen					0%	
Heizbetrieb ohne Luftvolumenstrom		17%				
Heizbetrieb ohne Wärmerückgewinnung (Rad)					52%	
Heizen und WRG Bypass aktiv		14%				0%
Niedrige Zulufttemperatur	2%	2%				
Niedrige Zu- und Ablufttemperatur	2%	1%				
Erwärmung der Zone über Außenluft (Sommer)	0%	0%		0%	25%	0%

Tabelle 25: Observierte Fehlertypen und deren Anteile an den fehlerbehafteten Daten der Fallstudien im ISC-Gebäude.

	CTA01	CTA02	CTA03	CTA08	CTA17
Fehleranteil der Daten	0,2%	0,8%	0,2%	3,1%	0,4%
Luftvolumenstrom und Anlage ausgeschaltet	2%				
Luftvolumenstrom über nominalem Wert		91%			
Asynchroner Betrieb der Ventilatoren	12%	1%	1%	12%	3%
Sollwert für die Ablufttemperatur wird nicht erreicht		3%		4%	
Keine Heizleistung bei geöffnetem HR-Ventil					3%
HR-Ventil geöffnet und HR-Pumpe aus		2%		61%	
Heizbetrieb ohne Wärmerückgewinnung (Rad)		0%			
Heizbetrieb mit aktiviertem WRG-Bypass				2%	
Falsche Position der Außenluftklappen	4%				
Automatikbetrieb abgeschaltet (Wartung der Anlage)	90%		99%	23%	75%
Umluftbetrieb ohne Heizen oder Kühlen					22%
Frequenties Ein- und Ausschalten					6%
WRG Betrieb nicht im Einklang mit den Temperaturen		1%			2%
Heizleistung bei geschlossenem HR-Ventil					1%
Zulufttemperatur Sollwert wird nicht erreicht		1%			

## 5. Darstellung und Analyse der Ergebnisse

Tabelle 26: Observierte Fehlertypen und deren Anteile an den fehlerbehafteten Daten der Fallstudien im MSA-Gebäude.

	AUD2	AUD4	AUD7	AUD8	AUD9	AUD11
<i>Fehleranteil der Daten</i>	48,3%	3,4%	9,8%	5,8%	24,9%	28,5%
ADK aktiv und $T_{AUL} < T_{ABL,nWRG}$	9%		3%		0%	10%
Adiabate Kühlung aktiv und Pumpensignal = 0			8%			
Keine adiabate Kühlung und Pumpensignal = 1			0%			
Keine Frischwasserzufuhr für das ADK-System		1%		17%		
Asynchroner Betrieb der Ventilatoren	0%	12%	0%	0%	0%	0%
Kühlung ohne WRG-Betrieb					0%	0%
RLT-Eingeschaltet, aber Ventilatoren aus			0%			
Fehlerhafter Sensorwert	0%	1%	0%	0%	0%	0%
Eingefrorener Sensorwert						47%
Keine Heizleistung bei geöffnetem HR-Ventil		0%	5%	0%		
HR-Ventil in fester Position			0%			
HR-Ventil geöffnet und HR-Pumpe aus	1%	31%	2%		28%	40%
Gleichzeitiges Heizen und adiabates Kühlen	24%		3%	1%	1%	8%
Heizbetrieb ohne Luftvolumenstrom			9%			
Heizbetrieb ohne Wärmerückgewinnung (Rad)	0%	53%	40%	40%	9%	5%
Heizbetrieb bei $T_{Raum} > T_{Raum, Soll}$	71%	0%		0%		
Erwärmung der Zone über die WRG (Sommer)			1%			
Falsche Position der Außenluftklappen					0%	
Kein Luftvolumenstrom bei Ventilatorsignal = 1			23%			1%
Erwärmung der Zone über Außenluft (Sommer)	6%		0%	23%	1%	
Umluftbetrieb ohne Heizen oder Kühlen	0%		3%	18%	60%	0%
Umluftbetrieb mit Heizvorgang bei $T_{Raum} > T_{Raum, Soll}$			1%			
WRG Betrieb nicht im Einklang mit den Temperaturen		3%	0%			
Heizleistung bei geschlossenem HR-Ventil	52%					

Im Betrieb der Fallstudien der GSHN lässt sich vorrangig das Symptom „Keine Heizleistung bei geöffneten HR-Ventil“ aufgrund einer abgeschalteten zentralen Wärmeversorgung in den Übergangszeiten zwischen Sommer und Winter beobachten. Dies führt jedoch nur in der Versorgungszone der Anlage FLA zu einer erkennbaren Beeinträchtigung des Raumkomforts (Fehlersymptom: „Niedrige Zu- und Ablufttemperatur“). Die Fehlertypen „Heizbetrieb ohne Luftvolumenstrom“ und „Heizen ohne WRG“ können ausschließlich für die RLT-Anlage FLB beobachtet werden. Diese treten jedoch nur in zeitlich abgrenzbaren Bereichen in den Datensätzen auf. Für die RLT-Anlage AUL ist auffällig, dass häufig ein „Heizbetrieb ohne WRG (Rad)“ und ein „Erwärmung der Zone über Außenluft (Sommer)“ auftritt. Diese Symptome sind eine Folge eines invers arbeitenden HR-Ventils.

Deutlich diverser sind die gefundenen Labels für die RLT-Anlagen im MSA-Gebäude. Auffällig sind die hohen Fehleranteile für die Anlagen AUD2 und AUD11, die durch eine HR-Ventil-Leckage und eines regelmäßig einfrierenden Sensormesswertes

## 5. Darstellung und Analyse der Ergebnisse

---

verursacht werden. Die Fehlertypen der übrigen RLT-Anlagen können meist auf ein ineffizientes Verhalten der Regelung zurückgeführt werden (z.B. Heizbetrieb ohne WRG). Eine Ausnahme stellt eine Fehlfunktion der adiabaten Kühlung im Betrieb der Anlage AUD8 aufgrund eines geschlossenen Frischwasserventils dar.

Der Betrieb der RLT-Anlagen im ISC-Gebäude ist durch sehr geringe Fehleranteile gekennzeichnet. Dadurch führt bereits eine kleine Anzahl von Symptomen zu hohen relativen Anteilen am gesamten Fehler-Datensatz (bspw. asynchroner Betrieb der Ventilatoren, CTA01). Die häufigsten Abweichungen vom Normalbetrieb können während der intervallmäßig durchgeführten Wartungsarbeiten (abgeschalteter Automatikbetrieb) identifiziert werden. Hierbei handelt es sich jedoch nicht per Definition um einen fehlerhaften Betrieb. Da die FED-Methodik systemisch nicht unterscheiden kann, ob ein abnormales Verhalten durch einen manuellen Eingriff verursacht wird, werden die Zeitbereiche als Fehlerzustand gelabelt. Liegen entsprechende Informationen aus dem Anlagenbetrieb vor, wie etwa durch eine Betriebsrückmeldung, können mögliche Alarmer während der Wartungsarbeiten in der späteren Anwendung gefiltert werden.

Die identifizierten Fehlertypen werden im Folgenden genutzt, um das Potenzial des entwickelten Residuen-generierenden Ansatzes zur Fehlerisolation zu untersuchen. Ergänzend können diese Daten dazu verwendet werden, um Probleme oder ineffiziente Betriebsweisen in den Fallstudien durch Betriebsoptimierungen zu beheben.

### 5.3.2. Ausprägung von Fehlermustern

Eine performante Fehlerisolation (FI) erfordert eine möglichst eindeutige Ausprägung der Fehlermuster. Hierzu können sowohl die generierten Residuen als auch die in der Residuen-Evaluierung ermittelten Scores zur Anwendung kommen.

In Abbildung 72 sind beide Varianten exemplarisch für einen einzelnen Fehlertyp als Box-Plot gegenübergestellt. Die Box zeigt den Wertebereich, den sogenannten Interquartilsabstand (IQR), in dem 50% der im Fehlerfall generierten Daten liegen. Der 1,5-fache Wertebereich des IQR wird durch die sogenannten Whiskers (Antennen) markiert. Residuen, die außerhalb dieses Wertebereichs liegen, werden als Ausreißer im Diagramm durch das Symbol "x" gekennzeichnet.

Durch das Scoring prägen sich im Vergleich zu den Residuen tendenziell höhere Beträge in den Variablen aus, wodurch in Abbildung 72 visuell der Eindruck einer stärkeren Ausprägung des Fehlermusters entsteht (z.B. für die Variable  $T_{HR,hydRL}$ ). Tatsäch-

lich führt das Scoring-Verfahren jedoch zu einem Informationsverlust, da durch das eingeführte Toleranzband und die obere Residuen-Grenze nur eine Teilmenge des gesamten Wertebereiches berücksichtigt wird. Zudem ist die Fehlerrichtung (positiv / negativ) anhand der Scores nicht erkennbar. Die generierten Residuen bieten daher eine wesentlich breitere Informationsbasis und sind im Vergleich zu den Scores deutlich besser für die Anwendung eines Klassifikationsverfahrens zur Fehlerisolierung geeignet.




Abbildung 72: Exemplarische Darstellung der resultierenden Muster in den Scores (links) und den Residuen (rechts) für den Fehlertyp „HR-Ventil offen und keine Heizleistung“.

Für die Analyse der Fehlermuster und insbesondere zur Beurteilung, ob es sich um ein für den Fehlertyp charakteristisches Muster handelt, ist es wichtig, möglichst viele Daten des jeweiligen Fehlertyps zur Verfügung zu haben. Je größer der Datensatz, desto repräsentativer ist das generierte Muster. Die in Abschnitt 5.3.1 angegebenen relativen Anteile der beobachteten Fehlertypen in den fehlerbehafteten Daten (Tabelle 24 bis Tabelle 26) bieten einen guten Überblick darüber, welche Fehlertypen in den jeweiligen Anlagen vorherrschen. Die absolute Anzahl der verfügbaren Daten für die Generierung eines Fehlermusters lässt sich jedoch nicht unmittelbar ableiten. In den Anhängen A18, A20 und A22 sind daher ergänzend die Anzahl der Datensätze je Fehlertyp und Anlage im Trainings-, Test- sowie im gesamten Auswertzeitraum aufgeführt. Für die folgenden exemplarischen Analysen werden Fehlertypen verwendet, die in möglichst großer Anzahl und in allen Zeiträumen vertreten sind. Eine gesammelte Darstellung aller observierten Fehlermuster ist den Anhängen A19, A21 und A23 zu entnehmen.

Wie die Anzahl der Datensätze die Ausprägung eines Musters in den Residuen beeinflusst, zeigt Abbildung 73. Hierzu wurden für den Fehlertyp „Heizen ohne WRG“ zufällig Residuen-Datensätze ausgewählt, wobei die Anzahl in den dargestellten Boxplots schrittweise erhöht wurde. Auffällig ist, dass sich schon bei einer kleinen Stichprobe

## 5. Darstellung und Analyse der Ergebnisse

von fünf Datensätzen die wesentliche Struktur des Musters herausbildet. Charakteristisch sind hohe Residuen nahe -1 für das Stellsignal der Wärmerückgewinnung ( $U_{WRG}$ ) sowie erhöhte Residuen für die Zulufttemperatur nach der WRG ( $T_{ZUL,nWRG}$ ) und das Stellsignal für das Heizregisterventil ( $U_{HR,Ventil}$ ). Mit zunehmender Vergrößerung der Datenbasis verändert sich die Lage der Mediane nur geringfügig, wobei die größte Veränderung von 0,24 auf 0,12 für  $U_{HR,Ventil}$  beobachtet werden kann. Etwas stärkere Veränderungen sind für den zu erwartenden Wertebereich der Residuen festzustellen. Bis zu einer Anzahl von 50 Datensätzen vergrößert sich der Interquartilsabstand für nahezu alle Variablen. Darüber hinaus (>50 Datensätzen) sind nur noch geringe Veränderungen zu beobachten.




Abbildung 73: Entwicklung des Residuen-Musters für den Fehlertyp „Heizbetrieb ohne WRG“ bei zunehmender Anzahl (5,10,50,400) zufällig ausgewählter Datensätzen aus dem Betrieb der RLT-Anlage AUD8 im MSA.

Die FI-Performance hängt maßgeblich von der Trennbarkeit der generierten Fehlermuster in Bezug auf den beobachteten Fehlertyp ab. Im Folgenden wird exemplarisch gezeigt, dass sich in den Residuen einer einzelnen RLT-Anlage eindeutige Muster für verschiedene Fehlertypen herausbilden. Abbildung 75 veranschaulicht die Analyse von vier Fehlertypen der RLT-Anlage AUD8 im MSA-Gebäude.

Alle Fehlertypen prägen durch unterschiedliche Positionen des Interquartilsabstands (Boxen) für die beobachteten Variablen eindeutige Residuen-Muster aus<sup>22</sup>. Bei einer Erwärmung der Zone über die Außenluft (In Abbildung 75 oben links) treten die größten Residuen für das Stellsignal der WRG ( $U_{WRG}$ ) auf, mit einem Median von -0,65. Im Heizbetrieb ohne Wärmerückgewinnung (oben rechts) sind die Abweichungen mit einem Median von -0,98 noch deutlicher ausgeprägt. Zusätzlich gibt es Residuen für das Stellsignal des Heizregisterventils ( $U_{HR-Ventil}$ ). Beim Umluftbetrieb ohne Heizen oder Kühlen zeigen sich hingegen deutliche Abweichungen für das Stellsignal des Abluft-

<sup>22</sup> Ergänzend zu der hier durchgeführten visuellen Analyse, zeigt Anhang A17 eine lineare Diskriminanzanalyse der betrachteten Symptom-Muster. Durch die Transformation der Muster in einen zweidimensionalen Merkmalsraum wird das Klassifizierungspotential in einem Scatterplot veranschaulicht.



## 5. Darstellung und Analyse der Ergebnisse

ventilators ( $U_{ABL-Ven}$ ) mit einem Median von -0,75. Eine blockierte Frischwasserzufuhr für das adiabate Kühlsystem (ADK) führt im Gegensatz zu den vorherigen Beispielen zu positiven Residuen für das Stellsignal der WRG ( $U_{WRG}$ ). Zudem sind Residuen für das Pumpensignal der ADK ( $U_{ADK,Pu}$ ) charakteristisch für diesen Fehlertyp.




Abbildung 74: Muster in den Residuen ausgewählter Fehlertypen der RLT-Anlage AUD8 im MSA-Gebäude (gesamter Auswertzeitraum).

Auch in den Temperatur- und Feuchte-Variablen zeigen sich für alle Fehlertypen Unterschiede. Beispielsweise treten bei einer Fehlfunktion in der adiabaten Kühlung tendenziell positive Residuen in den Temperatur-Variablen auf, während für ein Heizen ohne WRG negative Residuen für die Zulufttemperatur nach der WRG ( $T_{ZUL,nWRG}$ ) typisch sind.

In allen Fällen lassen sich Residuen mit größeren Beträgen durch die Wirkungsstruktur des Systems erklären, sodass die betreffenden Variablen auch wertvolle Hinweise für eine manuelle Fehlerdiagnose liefern können. Im Umluftbetrieb wird beispielsweise der Abluftventilator abgeschaltet und die Umluftklappe geöffnet, um die Versorgungszone

## 5. Darstellung und Analyse der Ergebnisse

mit Wärme oder Kälte zu versorgen. Da im beschriebenen Fehlerfall jedoch weder geheizt noch gekühlt wird, prognostizieren die Modelle einen Frischluftbetrieb. Dies führt zu hohen Residuen beim Stellsignal des Ventilators und der Umluftklappe.

Darüber hinaus kann die Übertragbarkeit der Fehlermuster untersucht werden. Dies ist insofern von Bedeutung, da in der Regel nur wenige Daten zum Erlernen von Fehlermustern verfügbar sind. Wenn eine identische Symptomausprägung anlagenübergreifend auftritt, kann die Datenbasis für das Trainieren klassifizierender ML-Modelle deutlich erweitert werden. Abbildung 75 zeigt die Residuen-Muster des Fehlertyps „HR-Ventil offen und keine Heizleistung“ für drei unterschiedliche RLT-Anlagen im GSHN-Gebäude. Die untersuchten Anlagen (FLA, FLB, FA) verfügen über eine identische Systemkonfiguration, Anzahl der erfassten Datenpunkte und Regelstrategie. Unter diesen Bedingungen zeigen alle Anlagen vergleichbare Fehlermuster.




Abbildung 75: Fehlermuster des Fehlertyps „HR-Ventil offen und keine Heizleistung“ für RLT-Anlagen mit gleicher Systemkonfiguration.

Eine Analyse weiterer Fehlertypen oder ein Vergleich zwischen RLT-Anlagen mit unterschiedlichen Systemkonfigurationen gestaltet sich jedoch deutlich schwieriger. Identische Fehlertypen treten selten in einer statistisch relevanten Häufigkeit im Betrieb mehrerer Anlagen auf, wodurch eine aussagekräftige Analyse erschwert wird.

Abbildung 76 verdeutlicht eine grundlegende Herausforderung bei RLT-Anlagen mit unterschiedlicher Systemkonfiguration. Hier wird das Fehlermuster für den Fehlertyp „HR-Ventil offen und keine Heizleistung“ der Anlage FLA im GSHN-Gebäude dem Muster der Anlage AUD7 im MSA-Gebäude gegenübergestellt. Aufgrund der unterschiedlichen Systemkonfiguration stehen unterschiedliche Datenpunkte für die Residuen-Generierung zur Verfügung, sodass nur eine kleine Schnittmenge (hier fünf Variablen) für eine übertragende FI genutzt werden kann.

Zudem prägen sich, aufgrund der unterschiedlichen Betriebsstrategie, die Residuen in unterschiedlichen Variablen aus. Im MSA-Gebäude, mit einer bedarfsgeführte Volumenstromregelung, treten Residuen bei den Stellsignalen der Ventilatoren auf. Im Gegensatz dazu sind in der GSHN-Anlage mit einer zweistufigen Regelung keine Abweichungen bei den Volumenströmen erkennbar. Es ist jedoch zu beachten, dass für die Boxplot-Darstellung der Anlage AUD7 lediglich zehn Datensätze verfügbar sind, was einen aussagekräftigen Vergleich einschränkt.




Abbildung 76: Fehlermuster des Fehlertyps „HR-Ventil offen und keine Heizleistung“ für RLT-Anlagen mit unterschiedlicher Systemkonfiguration.

### 5.3.3. Isolation typischer Fehlermuster

Die Fehlerisolation (FI) erfolgt nach der in Abschnitt 3.5 vorgestellten Methodik auf Basis einer Random-Forest-Klassifizierung der Fehlermuster. Für das Modelltraining und einer anschließenden Performance-Bewertung ist es notwendig, dass der zu isolierende Fehler sowohl im Trainings- als auch im Testzeitraum vorhanden ist. Da Fehler selten wiederkehrend auftreten, es sei denn sie sind systemischen Ursprungs, stellt dies die Anwendung von lernenden Methoden vor eine besondere Herausforderung. In den untersuchten Fallstudien können daher nur einzelne Fehlermuster für eine FI erlernt werden.

Ein wiederkehrender Fehlertyp für die RLT-Anlagen im GSHN-Gebäude ist der Betrieb mit offenem Heizventil ohne Erwärmung der Zuluft. Die Klassifizierungsergebnisse der Fehlerisolation sind in Tabelle 27 dargestellt. Die Anlage AULA wurde aufgrund des invers arbeitenden Heizregisterventils nicht berücksichtigt. In allen betrachteten Anlagen wird der Fehler mit hohen Fehlerisolationraten (*FIR*) von über 84 % isoliert. Eine Ausnahme bildet die RLT-Anlage FLA: Trotz eines großen Trainingsdatensatz ( $n_{Train}$ ) wird nur eine *FIR* von 64 % erreicht. Ein wesentlicher Grund für die schlechtere Per-

## 5. Darstellung und Analyse der Ergebnisse

formance ist die unvollständige Identifikation des Fehlertyps über den gesamten Zeitraum seines Auftretens. Dies zeigt Abbildung 77 anhand eines Zeitreihenbeispiels. Am 4. September tritt der Fehlertyp, gekennzeichnet durch den Fehlertypstatus (*FTS*) als Ergebnis des Labeling-Prozesses, über einen Zeitraum von vier Stunden auf (08:30 bis 12:30), kann jedoch nur für ca. eine Stunde korrekt isoliert werden.

Tabelle 27: Ergebnisse der Fehlerisolation für den Fehlertyp „Heizventil geöffnet und keine Erwärmung der Zuluft“ im Betrieb der RLT-Anlagen im GSHN-Gebäude. Die dargestellten Metriken beziehen sich auf den Testzeitraum.

	$n_{Train}$	$n_{Test}$	$f_{FT,Test}$	<i>CR</i>	<i>MisCR</i>	<i>FIR</i>	<i>FAR</i>
FLA	1189	153	58.2%	78.4%	21.6%	64.0%	1.6%
FLB	64	624	12.5%	59.3%	40.7%	100.0%	46.5%
FLC	83	99	32.3%	94.9%	5.1%	96.9%	6.0%
FA	919	418	68.9%	92.3%	7.7%	90.6%	3.8%
SPO	948	574	38.0%	86.2%	13.8%	84.1%	12.4%

$n_{Train}$ : Anzahl der Trainingsdaten,  $n_{Test}$ : Anzahl der Testdaten,  $f_{FT,Test}$ : Fehlertypanteil im Testzeitraum, *CR*: Klassifizierungsrate, *MisCR*: Fehlklassifizierungsrate, *FIR*: Fehlerisolutionsrate, *FAR*: Fehlalarmrate




Abbildung 77: Zeitreihenbeispiel der Fehlerisolation für den Fehlertyp „Heizventil geöffnet und keine Erwärmung der Zuluft“ im Betrieb der RLT-Anlagen FLA im GSHN-Gebäude.

Zusätzlich ist in Abbildung 77 erkennbar, dass die Fehlerisolation (*FI*) nur bei einer erfolgreichen Fehlererkennung (*FE*) durchgeführt wird. Während der Fehlertyp am 4. und 5. September korrekt isoliert wird, ist dies am 6. September aufgrund einer verpassten Fehlererkennung nicht möglich. Um eine Bewertung der Fehlerisolation unabhängig von der Performance der vorgelagerten Fehlererkennung zu ermöglichen, beziehen sich die in Tabelle 27 aufgeführten Metriken ausschließlich auf Zeiträume mit erfolgreicher Fehlererkennung.

Für die RLT-Anlage FLB ist eine hohe fehlerhafte Zuordnung des Fehlermusters mit einer FAR von 46,5 % zu beobachten. Im Trainingszeitraum stehen nur wenige fehlerhafte Betriebsdaten zur Verfügung, was dazu führt, dass das Fehlermusters nicht ausreichend erlernt wird. Ein möglicher Lösungsansatz besteht darin, das Muster von baugleichen Anlagen zu erlernen. Um diesen Ansatz zu testen, werden die Fehlerdaten von FLA, FLB, FLC und FA für das Modelltraining eines gemeinsamen FI-Modells genutzt. Für die Anlage FLB kann dadurch die Klassifizierungsrate ( $CR$ ) von 78% auf 88% gesteigert und die  $FAR$  signifikant auf 8% reduziert werden. Die FI-Performance für die übrigen Anlagen wird durch diesen Ansatz jedoch nicht wesentlich beeinflusst. Eine Notwendigkeit ein übertragendes Lernen anzuwenden, muss daher im Einzelfall geprüft werden und ist nur dann sinnvoll, wenn sich ähnliche Fehlermuster ausprägen.

*Tabelle 28: Ergebnisse der Fehlerisolation für den Fehlertyp „Heizventil geöffnet und keine Erwärmung der Zuluft“ im Betrieb der RLT-Anlagen im GSHN-Gebäude. Die dargestellten Metriken beziehen sich auf den Testzeitraum.*

	$n_{Train}$	$n_{Test}$	$f_{FT,Test}$	$CR$	$MisCR$	$FIR$	$FAR$
FT1	1079	1000	7,7%	99,2%	0,8%	89,6%	0,0%
FT2			0,3%	99,7%	0,3%	66,7%	0,2%
Gesamt			-	98,9%	1,1%	88,8%	0,2%

FT1: Umluftbetrieb ohne Heizen oder Kühlen, FT2: Heizbetrieb ohne Wärmerückgewinnung

$n_{Train}$ : Anzahl der Trainingsdaten,  $n_{Test}$ : Anzahl der Testdaten,  $f_{FT,Train}$ : Fehlertypanteil im Testzeitraum,  $CR$ : Klassifizierungsrate,  $MisCR$ : Fehlklassifizierungsrate,  $FIR$ : Fehlerisolutionsrate,  $FAR$ : Fehlalarmrate

Die Fehlerisolierung (FI) für mehr als einen Fehlertyp ist aufgrund der limitierten Verfügbarkeit von Trainings- oder Testdaten ausschließlich für die RLT-Anlage AUD8 im MSA-Gebäude möglich. Tabelle 28 listet die Ergebnisse für die Isolation der Fehlertypen „Umluftbetrieb ohne Heizen oder Kühlen“ (FT1) und „Heizbetrieb ohne Wärmerückgewinnung“ (FT2). Mit einer Klassifizierungsrate ( $CR$ ) von 99% können beide Fehlertypen gut voneinander unterschieden und von den Mustern unbekannter Fehlertypen isoliert werden. Einen visuellen Eindruck über den gesamten Testzeitraum liefert die Zeitreihendarstellung in Abbildung 78. Eine fehlerhafte Zuordnung tritt mit einem Anteil von 0,2% selten auf und beschränkt sich ausschließlich auf Zeiträumen mit Fehlalarmen der Fehlererkennung. Der Fehlertyp „Heizbetrieb ohne Wärmerückgewinnung“ tritt im Testzeitraum nur einmal auf und wird korrekt erkannt. Da jedoch nicht der gesamte Zeitraum positiv markiert ist, ergibt sich eine im Vergleich zum Fehlertyp 1 geringere Fehlerisolutionsrate ( $FIR$ ) von 67%. Betrachtet man die Gesamtperformance

## 5. Darstellung und Analyse der Ergebnisse

(FIR), wird ein Anteil von 89% der analysierten Fehlertypen richtig erkannt und zugeordnet.




Abbildung 78: Zeitreihenbeispiel der Fehlerisolation für die RLT-Anlage AUD8 im MSA-Gebäude. Die Isolation erfolgt für die Fehlertypen „Umluftbetrieb ohne Heizen oder Kühlen“ (Typ 1) und „Heizbetrieb ohne Wärmerückgewinnung“ (Typ 2).

### 5.3.4. Zusammenfassung und Diskussion

Die Betriebsdaten der Fallstudien liefern eine breite Datenbasis für verschiedene Ursachen eines ineffizienten oder fehlerhaften Betriebs von RLT-Anlagen. Anhand dieser Daten lässt sich zeigen, dass der angewandte Residuen-generierende Ansatz für jeden Fehlertyp charakteristische Fehlermuster im Residuen-Vektor ausbildet, wodurch die Grundlage für die Fehlerisolation geschaffen wird.

Hohe Residuen treten häufig in den Variablen auf, die unmittelbar durch den beobachteten Fehlertyp beeinflusst werden. Dies liefert erste Hinweise für eine manuelle Fehldiagnose. Es ist jedoch zu beachten, dass die Sensitivität einer Schätzung stark von den Gewichtungsfaktoren innerhalb der MLP-Netzwerke abhängt. Da diese Faktoren anhand statistischer Zusammenhänge erlernt werden, können auch Residuen in Variablen auftreten, bei denen physikalisch keine Abweichungen zu erwarten sind.

In den untersuchten Fallstudien zeigt sich, dass nur selten identische Fehlertypen in mehreren RLT-Anlagen beobachtet werden. Hierdurch wird eine statistisch signifikante Auswertung zur Übertragbarkeit der Fehlermuster erschwert. Anhand eines Beispiels

konnte jedoch gezeigt werden, dass RLT-Anlagen mit identischer Konfiguration ähnliche Fehlermuster ausbilden. Bei Anlagen mit unterschiedlichen Systemkonfigurationen besteht das Problem, dass nicht die gleichen Datenpunkte erfasst werden. Dies führt zu einer geringen Schnittmenge für den Abgleich der Residuen-Muster. Darüber hinaus kann die implementierte Regelstrategie einen erheblichen Einfluss auf die Ausprägung der Residuen haben. Eine generelle Übertragbarkeit der Fehlermuster bei unterschiedlichen Konfigurationen und Nutzungen der Versorgungszonen ist dadurch stark eingeschränkt.

Fehler treten meist nur in begrenzten Zeiträumen auf, was das Erlernen von Fehlermustern auf Basis historischer Betriebsdaten auf systemisch auftretende und wiederkehrende Fehlertypen beschränkt. Dies zeigt eine grundsätzliche Grenze selbstlernender Ansätze bei der Erstellung von Fehlermodellen. Anhand der Fallstudien kann aber gezeigt werden, dass eine Fehlerisolation durch den Einsatz klassifizierender ML-Modelle (hier Random-Forest) auf Basis der Fehlermuster möglich ist. Mit Fehlerisolationen von meist über 85 % wird eine gute Performance erreicht.

Ein wesentlicher Grund für die reduzierten Performance-Indikatoren ist, dass der Fehler häufig nicht über den gesamten Zeitraum seines Auftretens isoliert wird. Da der Fehlertyp jedoch grundsätzlich erkannt wird, kann die Darstellung für den Nutzer durch eine geeignete Nachverarbeitung weiter verbessert werden. Zudem wird die Fehlerisolation ausschließlich nach einer erfolgreichen Fehlererkennung durchgeführt. Das bedeutet, dass Zeiträume mit verpassten Alarmen nicht ausgewertet werden und Fehlalarme zu einer irrtümlichen Zuordnung führen können.

Ist keine Isolierung des Fehlers möglich, muss eine manuelle Prüfung erfolgen. Wenn es sich um einen bereits zuvor beobachteten Fehler handelt, können die fehlerhaften Residuen dem Trainingsdatensatz hinzugefügt und ein Update des Fehlermodells durchgeführt werden. Bei einem bisher unbekanntem Fehlertyp und ausreichender Datenmenge kann für die zukünftige Anwendung ein neues Klassifizierungsmodell trainiert werden.

Ein möglicher Lösungsansatz, um der begrenzte Datenverfügbarkeit zu begegnen, sind Methoden aus dem Bereich des Transferlernens. Hier werden die Fehlermuster anhand von Betriebsdaten anderer Systeme erlernt. An einem Beispiel kann gezeigt werden, dass das Training des Fehlermodells anhand der historischen Daten mehrerer Anlagen die Performance zur Isolation eines systemischen Fehlers bei baugleichen RLT-Anlagen steigern kann. Insbesondere die Fehlalarmrate kann deutlich reduziert

## 5. Darstellung und Analyse der Ergebnisse

---

werden. Dies ist jedoch nur vorteilhaft, wenn für die betrachtete Anlage unzureichende Daten zum Erlernen des Fehlermusters vorliegen und muss im Einzelfall geprüft werden.



### 6. Zusammenfassung und Ausblick

Diese Arbeit beschäftigt sich mit der Entwicklung und Anwendung einer Methodik zur automatisierten Fehlererkennung und -diagnose (FED) von raumluftechnischen Anlagen (RLT). Durch die Nutzung maschineller Lernverfahren (ML), die auf Basis historischer Betriebsdaten trainiert werden, wird der Implementierungsaufwand signifikant reduziert und die Übertragbarkeit auf neue Systeme verbessert. Dies zielt darauf ab, Hemmnisse in der praktischen Anwendung zu überwinden und eine verstärkte Nutzung von FED-Systemen für die kontinuierliche Betriebsüberwachung zu fördern. Darüber hinaus ermöglicht der verfolgte Ansatz nicht nur die Fehlererkennung, sondern auch eine weiterführende Fehlerdiagnose, wodurch zusätzliche Mehrwerte für die Anwendung im Facility Management generiert werden können.

#### 6.1. Zentrale Ergebnisse

Die Ergebnisse dieser Arbeit zeigen, dass die Einbettung von ML-Methoden in einen Residuen-generierenden FED-Prozess ein vielversprechender Ansatz ist. Dabei wird das nominale Verhalten des Systems geschätzt und die Abweichungen zu den beobachteten Daten berechnet. Diese Residuen tragen Informationen über den Fehlerzustand des Systems und bilden somit die Grundlage für die FED.

Eine entscheidende Herausforderung bei der Anwendung von ML-Methoden ist die Bereitstellung einer guten Datenbasis für das Training der Modelle. In der praktischen Anwendung stehen jedoch keine oder nur sehr wenige fehlerhafte Daten zur Verfügung, sodass das direkte Erlernen eines fehlerhaften Verhaltens schwierig ist. Ein wesentlicher Vorteil des Residuen-generierenden Ansatzes besteht daher darin, dass zum Trainieren der Modelle ausschließlich nominale Betriebsdaten verwendet werden.

Zum Einsatz kommen Multi-Layer-Perceptron (MLP) Neuronale Netze (NN) mit einer Bayes'schen Optimierung zum Tunen der Hyperparameter. Diese werden individuell für jede Schätzgröße erstellt, wodurch sich die Gesamtarchitektur an die Anzahl erfasster Datenpunkte aus dem System automatisch adaptieren kann. Hierdurch wird nicht nur eine gute Übertragbarkeit, sondern auch eine leichte Implementierung ohne tiefgehendes Expertenwissen im Bereich des ML erreicht.

Die Leistungsfähigkeit des entwickelten Ansatzes wurde in 17 Fallstudien auf Basis realer Daten aus dem Betrieb von RLT-Anlagen aus drei verschiedenen Gebäuden untersucht. Dabei zeigte sich, dass die MLP- NN in der Lage sind, eine hohe Genauigkeit bei der Schätzung des nominalen Verhaltens zu erzielen. Für einzelne Anlagen ist

jedoch eine Abnahme der Schätzgenauigkeit zu beobachten, was auf die unterschiedlichen Regelstrategien, Nutzungsmuster und technischen Ausstattungen der RLT-Anlagen zurückzuführen ist. Anlagen mit einfachen Regelstrategien und einer geringen Anzahl möglicher Betriebszustände erreichen eine höhere Schätzgüte als komplexere Anlagen mit vielen transienten Zuständen, wie im Fall der RLT-Anlagen im Maison du Savoir (MSA). Die Ergebnisse verdeutlichen die Bedeutung einer sorgfältigen Auswahl des Trainingszeitraums, der mindestens eine Dauer von sechs bis zwölf Monaten abdecken sollte. Zudem wird ein Modellupdate notwendig, wenn sich die Betriebsbedingungen in der Anwendungsphase ändern.

Dies verdeutlicht die Notwendigkeit, die Evaluierungsmethodik in einem automatisierten FED-Prozess so zu gestalten, dass sie sich an die individuelle Schätzgüte der Systemvariablen anpasst. Zu diesem Zweck wurde eine Methode zur Residuen-Evaluierung entwickelt, die automatisiert auf Basis der Trainingsergebnisse parametrisiert wird. Das zentrale Element der Methode ist ein variables Toleranzband, das die Unsicherheiten bei der Schätzung des nominalen Verhaltens berücksichtigt. Das Toleranzband wird dynamisch an den jeweiligen Betriebsmodus der Anlage (Heizen, Kühlen etc.) angepasst, um einerseits Fehlalarme zu minimieren und andererseits in gut erlernten Betriebsmodi eine hohe Sensitivität der Fehlererkennung (FE) zu erreichen. Zusätzlich werden die Residuen in den fehleranfälligen Wertebereichen durch ein Scoring normalisiert. Dies ermöglicht die Berechnung eines aussagekräftigen Gesamtscores für eine grenzwertbasierte FE, welcher die Signifikanz der einzelnen Residuen berücksichtigt. Durch die Scoring-basierte Normalisierung wird zudem erreicht, dass ein Standard-Grenzwert für das Triggern eines Fehlersignals verwendet werden kann.

Die Anwendung der Scoring-Methodik auf die Fallstudien zeigt im Vergleich zur direkten Auswertung der Residuen auf Basis der L2-Norm eine deutliche Verbesserung der Fehlererkennungs-Performance. Insbesondere die Fehlalarmrate (FAR) und die Anzahl der Alarme werden für einen Großteil der Anlagen signifikant reduziert, ohne die Sensitivität zu beeinträchtigen. Höhere Fehlalarmraten treten hauptsächlich bei den RLT-Anlagen des MSA-Gebäudes auf, da sich dort die Schätzqualität des nominalen Verhaltens unter veränderten Randbedingungen verschlechtert. So führte beispielsweise eine lange Hitzeperiode im MSA-Gebäude zu einer erhöhten Anzahl an Fehlalarmen. Dies verdeutlicht, dass statistische Ansätze zur Fehlererkennung nur bedingt zwischen seltenen, aber regulären Betriebszuständen und tatsächlichen Fehlern unterscheiden können.

Deutliche Vorteile zeigen sich in der Sensitivität gegenüber Fehlern. Im Vergleich zu einem regelbasierten Expertensystem erreicht der Residuen-generierende Ansatz eine deutlich höhere Fehlererkennungsrate (FDR) und erkennt auch Fehler, für die im Expertensystem keine spezifischen Regeln definiert wurden. Zudem werden die Parameter automatisiert bestimmt, während bei einem regelbasierten System die Anzahl der Parameter mit der Anzahl der Regeln korreliert. Mit zunehmender Komplexität des beobachteten Systems steigt daher auch der Aufwand für die Parametrisierung der Regeln.

Das Verhalten komplexer Methoden aus dem Bereich des maschinellen Lernens (ML) ist für Anwender oft schwer nachvollziehbar. Im Gegensatz dazu bleiben beim Residuen-generierenden Ansatz die Teilergebnisse für den fachlichen Anwender verständlich, was tendenziell zu einem größeren Vertrauen in das System führt. So können beispielsweise Variablen mit erhöhten Residuen direkt auf eine mögliche Fehlerursache hinweisen.

Anhand der Fallstudien konnte gezeigt werden, dass die in den Betriebsdaten gefundenen Fehlertypen charakteristische Muster in den Residuen ausprägen, die sich für die Fehlerisolierung eignen. Anhand von zwei Beispielen wurde demonstriert, dass die untersuchten Fehlertypen mithilfe eines Random-Forest-Ansatzes mit hoher Genauigkeit isoliert werden können. Für jeden Fehlertyp werden dabei individuelle Klassifizierungsmodelle trainiert. Voraussetzung dafür ist jedoch, dass der gesuchte Fehlertyp in ausreichender Menge in den historischen Betriebsdaten vorhanden ist, um ein Training durchführen zu können. Dies stellt ein wesentliches Hemmnis in der praktischen Anwendung dar. Eine mögliche Lösung besteht darin, Fehlermuster anlagenübergreifend zu erlernen. Aufgrund der begrenzten Datenbasis konnten keine statistisch signifikanten Auswertungen durchgeführt werden. Ähnliche Muster wurden jedoch in Anlagen mit identischer Konfiguration innerhalb desselben Gebäudes identifiziert, während unterschiedliche Systemkonfigurationen zu geringeren Übereinstimmungen führten. Insbesondere die Regelstrategie kann das Verhalten der RLT-Anlage im Fehlerfall und damit die Ausprägung von Mustern stark beeinflussen.

### 6.2. Zukünftige Forschungsarbeiten

In dieser Arbeit wurde das grundsätzliche Potential von ML-Methoden in einem Residuen-generierenden Ansatz untersucht. Zukünftige Forschungsarbeiten sollten sich auf die Verfeinerung und Weiterentwicklung der Methodik konzentrieren. Im Folgenden werden wesentliche Fragestellungen erläutert.

Um eine hohe Übertragbarkeit und flexible, adaptive Modellbildung zu erreichen, werden nahezu alle verfügbaren Datenpunkte der beobachteten Anlage zur Schätzung des nominalen Verhaltens verwendet. Dies kann jedoch zu komplexeren Modellstrukturen führen und höhere Anforderungen an die Rechenleistung stellen, ohne die Schätzqualität zu verbessern. Gleichzeitig besteht die Gefahr, dass innerhalb der Modellstruktur hohe Gewichtungsfaktoren für einzelne Eingangsgrößen gefunden werden, was die Sensitivität gegenüber Fehler, die sich in anderen Eingangsgrößen ausprägen, verringert. Die Auswirkungen unterschiedlicher Verfahren zur Auswahl der Eingangsgrößen sollte daher weiter untersucht werden. Zudem sind aufgrund der intensiven Forschung im Bereich des ML immer leistungsfähigere Modelltypen verfügbar, durch deren Einsatz eine Steigerung der Schätzqualität erreicht werden kann.

Die Scoring-Methode ermittelt die notwendigen Parameter für die Residuen-Evaluierung auf Basis vordefinierter Perzentil-Ränge der Residuen-Verteilung im Trainingszeitraum. Weiterführende Studien sollten die Auswirkungen der gewählten Perzentil-Ränge auf die Performance der Fehlererkennung untersuchen, um robuste Standardwerte zu definieren und Leitlinien für die praktische Anwendung zu formulieren. Diese Forschung könnte auch dazu beitragen, die Anzahl der Fehlalarme weiter zu reduzieren, ohne die Sensitivität gegenüber tatsächlichen Fehlern zu beeinträchtigen.

Bei der Implementierung des entwickelten Residuen-generierenden FED-Ansatzes müssen möglichst fehlerfreie Datensätze für das Erlernen der Parameter bereitgestellt werden. Um den Aufwand für das Filtern fehlerhafter Betriebszustände zu reduzieren, haben sich in dieser Arbeit Expertenregeln als sinnvoll erwiesen, deren Integration in den Gesamtprozess intensiviert werden kann. Ein Konzept-Schema zeigt Abbildung 79. Zunächst werden die Ergebnisse des Expertensystems genutzt, um häufig vorkommende Fehler in den Trainingsdaten des Residuen-generierenden Ansatzes zu filtern. In der anschließenden Anwendungsphase werden die Fehlererkennung (FE) von beiden Systemen parallel durchgeführt und die Resultate abgeglichen. Dabei kann

auch ein Qualitätsindex<sup>23</sup> erstellt werden, um die Interpretation der Ergebnisse zu erleichtern. Zudem ermöglicht die kombinierte Anwendung den Einsatz eines reduzierten Regelsatzes bei gleichzeitiger Steigerung der FE-Performance.

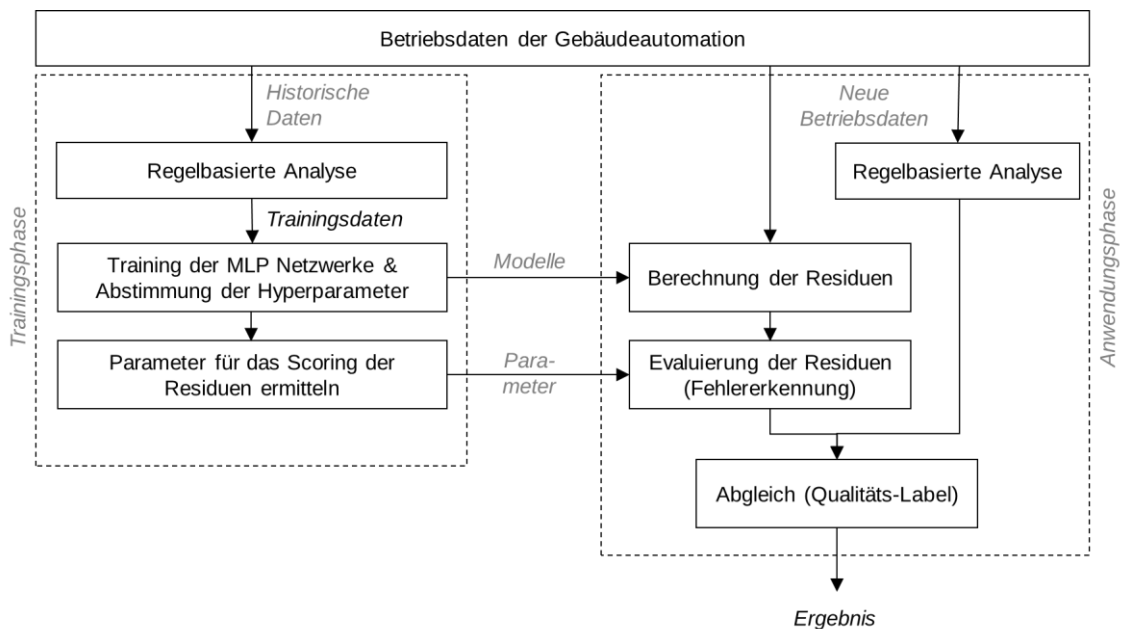


Abbildung 79: Konzept für die kombinierte Anwendung einer regelbasierten FE (Expertensystem) mit dem entwickelten Residuen-generierenden Ansatz.

Der größte Forschungsbedarf für eine praxistaugliche Anwendung liegt im Bereich der Fehlerisolierung (FI). In dieser Arbeit konnte zwar gezeigt werden, dass die resultierenden Fehlermuster grundsätzlich geeignet sind, jedoch sind weiterführende Untersuchungen zur Übertragbarkeit auf einer wesentlich größeren Datenbasis notwendig. Denkbar wäre beispielsweise die Erstellung eines Katalogs, der die Muster bestimmten Fehlertypen und Anlagenkonfigurationen zuordnet und beschreibt. Zudem könnte die FI durch die Einbeziehung dynamischer Effekte möglicherweise weiter verbessert werden. Aktuell erfolgt die Auswertung der Fehlermuster statisch für einzelne Zeitschritte.

Die Ergebnisse zeigen außerdem, dass für eine dauerhaft gute Performance der FED auch bei veränderten Randbedingungen Modellupdates in allen Teilschritten der Anwendungsphase notwendig sind. Dies kann entweder automatisiert durch eine Prüfung der Eingangsdaten oder durch Feedback des Nutzers erfolgen. Hierzu müssen geeignete Konzepte entwickelt werden.

<sup>23</sup> Bspw.: 3 = beide Methoden liefern ein positives Ergebnis, 2 = nur das Expertensystem liefert ein positives Ergebnis, 1 = nur der Residuen-generierende Ansatz liefert ein positives Ergebnis, 0 = kein Fehler)

## 6. Zusammenfassung und Ausblick

---

Ein weiteres vielversprechendes Forschungsfeld ist die Übertragung der entwickelten Methodik auf andere Komponenten von HLK-Systemen (z.B. hydraulische Systeme) in Gebäuden, wodurch das Anwendungsspektrum erheblich erweitert würde.

Schließlich müssen die gewonnenen Ergebnisse der FED in einer verständlichen und übersichtlichen Form für den Nutzer aufbereitet werden. Dazu gehört insbesondere eine Bewertung der Fehlergröße, indem die Auswirkungen auf den Energieverbrauch und den Raumkomfort auf Basis der Schätzungen des nominalen Verhaltens analysiert werden. Auf diese Weise lässt sich zusätzlich eine Priorisierung der Fehler vornehmen, wodurch neue Ansätze für die Planung von Wartungsarbeiten im Facility Management ermöglicht werden. Neben der Senkung der Energiekosten und einer Steigerung des Nutzerkomforts können so weitere Synergien in der Anwendung genutzt werden.

---

## Literatur

- [1] European Commission, „In focus: Energy efficiency in buildings“, 2020. [Online]. Verfügbar unter: [https://ec.europa.eu/info/news/focus-energy-efficiency-buildings-2020-feb-17\\_en](https://ec.europa.eu/info/news/focus-energy-efficiency-buildings-2020-feb-17_en).
- [2] S. Schunz, „The ‘European Green Deal’—a paradigm shift? Transformations in the European Union’s sustainability meta-discourse“, *Polit. Res. Exch.*, Bd. 4, Nr. 1, 2022, doi: 10.1080/2474736X.2022.2085121.
- [3] A. Ruffin, D. E. Claridge, und J. C. Baltazar, „The energy savings impact of the existing building commissioning process by building type“, *Sci. Technol. Built Environ.*, Bd. 27, Nr. 10, S. 1505–1521, 2021, doi: 10.1080/23744731.2021.1921492.
- [4] E. Crowe u. a., „Building commissioning costs and savings across three decades and 1500 North American buildings“, *Energy Build.*, Bd. 227, S. 110408, Nov. 2020, doi: 10.1016/J.ENBUILD.2020.110408.
- [5] S. Katipamula und M. R. Brambley, „Review article: Methods for fault detection, diagnostics, and prognostics for building systems—a review, part II“, *HVAC R Res.*, Bd. 11, Nr. 2, S. 169–187, 2005, doi: 10.1080/10789669.2005.10391133.
- [6] W. Kim und S. Katipamula, „A Review of Fault Detection and Diagnostics Methods for Building Systems“, *Sci. Technol. Built Environ.*, Bd. 24, S. 0, Apr. 2017, doi: 10.1080/23744731.2017.1318008.
- [7] H. Kramer, G. Lin, J. Granderson, C. Curtin, und E. Crowe, „Synthesis of Year Two Outcomes in the Smart Energy Analytics Campaign“, *U.S. Dep. Energy*, Nr. September 2017, 2019, doi: 10.5072/FK2736VK9J.
- [8] U. Rotermund, „Bedeutung der Energiekosten im Lebenszyklus einer Immobilie“, S. 10, 2020.
- [9] Europäisches Parlament und Rat der Europäischen Union, „Richtlinie (EU) 2024/864 des Europäischen Parlaments und des Rates vom 24. April 2024 zur Änderung der Richtlinie 2010/31/EU über die Gesamtenergieeffizienz von Gebäuden und der Richtlinie 2012/27/EU über Energieeffizienz“, Nr. 32024L0864. 2024, [Online]. Verfügbar unter: <https://eur-lex.europa.eu/legal-content/DE/TXT/?uri=CELEX:32024L0864>.
- [10] Journal Officiel du Grand-Duché de Luxembourg, „Règlement grand-ducal concernant la performance énergétique des bâtiments“, Nr. N° 439 du 9 juin 2021, 2021.
- [11] R. Isermann, *Fault-Diagnosis Applications*. Springer Verlag Heidelberg, 2011.
- [12] R. Isermann, *Fault-Diagnosis Systems – An Introduction from Fault Detection to Fault Tolerance*. Springer-Verlag Berlin Heidelberg, 2006.
- [13] S. X. Ding, *Model-Based Fault Diagnosis Techniques*. Springer-Verlag Berlin Heidelberg, 2013.
- [14] S. X. Ding, „Data-Driven Design of Observer-Based Fault Diagnosis Systems“, in *Advances in Industrial Control*, Nr. 9781447164098, 2014, S. 175–200.
- [15] S. P. Melgaard, K. H. Andersen, A. Marszal-Pomianowska, R. L. Jensen, und P. K. Heiselberg, „Fault Detection and Diagnosis Encyclopedia for Building Systems: A Systematic Review“, *Energies*, Bd. 15, Nr. 12, S. 4366, 2022, doi: 10.3390/en15124366.

- [16] S. Katipamula und M. R. Brambley, „Review article: Methods for fault detection, diagnostics, and prognostics for building systems—A review, part I“, *HVAC R Res.*, Bd. 11, Nr. 1, S. 3–25, 2005, doi: 10.1080/10789669.2005.10391123.
- [17] M. S. Mirnaghi und F. Haghghat, „Fault detection and diagnosis of large-scale HVAC systems in buildings using data-driven methods: A comprehensive review“, *Energy Build.*, Bd. 229, S. 110492, Dez. 2020, doi: 10.1016/J.ENBUILD.2020.110492.
- [18] S. X. Ding, *Data-driven Design of Fault Diagnosis and Fault-tolerant Control Systems*. London: Springer London, 2014.
- [19] C. Svärd, M. Nyberg, E. Frisk, und M. Krysander, „Data-driven and adaptive statistical residual evaluation for fault detection with an automotive application“, *Mech. Syst. Signal Process.*, Bd. 45, Nr. 1, S. 170–192, März 2014, doi: 10.1016/J.YMSSP.2013.11.002.
- [20] J. Navarro-Esbrí, E. Torrella, und R. Cabello, „A vapour compression chiller fault detection technique based on adaptative algorithms. Application to on-line refrigerant leakage detection“, *Int. J. Refrig.*, Bd. 29, Nr. 5, S. 716–723, Aug. 2006, doi: 10.1016/J.IJREFRIG.2005.12.008.
- [21] Y. Zhao, T. Li, X. Zhang, und C. Zhang, „Artificial intelligence-based fault detection and diagnosis methods for building energy systems: Advantages, challenges and the future“, *Renew. Sustain. Energy Rev.*, Bd. 109, S. 85–101, Juli 2019, doi: 10.1016/J.RSER.2019.04.021.
- [22] A. V Joshi, *Machine Learning and Artificial Intelligence*. Redmond: Springer International Publishing, 2020.
- [23] I. H. Sarker, „Machine Learning: Algorithms, Real-World Applications and Research Directions“, *SN Comput. Sci.*, Bd. 2, Nr. 3, S. 1–21, 2021, doi: 10.1007/s42979-021-00592-x.
- [24] I. H. Sarker, „Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions“, *SN Comput. Sci.*, Bd. 2, Nr. 6, S. 1–20, 2021, doi: 10.1007/s42979-021-00815-1.
- [25] Y. Zhang, *New Advances in Machine Learning*. 2012.
- [26] I. H. Witten, E. Frank, und M. A. Hall, *Data mining: practical machine learning tools and techniques*, 3rd ed. Burlington, MA: Morgan Kaufmann, 2011.
- [27] T. Hastie, R. Tibshirani, und J. Friedman, *The Elements of Statistical Learning*, Bd. 167, Nr. 1. New York, NY: Springer New York, 2009.
- [28] S. Badillo u. a., „An Introduction to Machine Learning“, *Clin. Pharmacol. Ther.*, Bd. 107, Nr. 4, S. 871–885, Apr. 2020, doi: 10.1002/cpt.1796.
- [29] R. J. Hyndman und G. Athanasopoulos, *Forecasting: principles and practice*, 3. Edition. OTexts, 2021.
- [30] L. Owen, *Hyperparameter Tuning with Python: Boost your machine learning model's performance via hyperparameter tuning*. Packt Publishing, 2022.
- [31] J. Hyvarinen und S. Karki, *Building Optimization and Fault Diagnosis Source Book*, Bd. 53, Nr. 9. 1996.
- [32] International Energy Agency und E. C. in B. and C. S. Programme, *Technical Synthesis Report IEA Annex 34: Computer Aided Evaluation of HVAC System Performance*. 2006.



- 
- [33] A. Dexter und J. Pakanen, „Demonstrating Automated Fault Detection and Diagnosis Methods in Real Buildings“, *VTT Symp. 217*, S. 381, 2001, [Online]. Verfügbar unter: <https://publications.vtt.fi/pdf/symposiums/2001/S217.pdf>.
- [34] A. Hosseini Gourabpasi und M. Nik-Bakht, „Knowledge Discovery by Analyzing the State of the Art of Data-Driven Fault Detection and Diagnostics of Building HVAC“, *CivilEng*, Bd. 2, Nr. 4, S. 986–1008, Nov. 2021, doi: 10.3390/civileng2040053.
- [35] W. Nelson und C. Culp, „Machine Learning Methods for Automated Fault Detection and Diagnostics in Building Systems—A Review“, *Energies*, Bd. 15, Nr. 15, 2022, doi: 10.3390/en15155534.
- [36] I. Matetić, I. Štajduhar, I. Wolf, und S. Ljubic, „A Review of Data-Driven Approaches and Techniques for Fault Detection and Diagnosis in HVAC Systems“, *Sensors*, Bd. 23, Nr. 1, S. 1–37, 2023, doi: 10.3390/s23010001.
- [37] G. Li, Y. Hu, J. Liu, X. Fang, und J. Kang, „Review on Fault Detection and Diagnosis Feature Engineering in Building Heating, Ventilation, Air Conditioning and Refrigeration Systems“, *IEEE Access*, Bd. 9, S. 2153–2187, 2021, doi: 10.1109/ACCESS.2020.3040980.
- [38] P. M. Frank und X. Ding, „Survey of robust residual generation and evaluation methods in observer-based fault detection systems“, *J. Process Control*, Bd. 7, Nr. 6, S. 403–424, Dez. 1997, doi: 10.1016/S0959-1524(97)00016-4.
- [39] Z. Gao, C. Cecati, und S. X. Ding, „A survey of fault diagnosis and fault-tolerant techniques-part II: Fault diagnosis with knowledge-based and hybrid/active approaches“, *IEEE Trans. Ind. Electron.*, Bd. 62, Nr. 6, S. 3768–3774, 2015, doi: 10.1109/TIE.2015.2419013.
- [40] S. X. Ding, *Advanced methods for fault diagnosis and fault-tolerant control*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2021.
- [41] Z. Gao, C. Cecati, und S. X. Ding, „A survey of fault diagnosis and fault-tolerant techniques-part I: Fault diagnosis with model-based and signal-based approaches“, *IEEE Trans. Ind. Electron.*, Bd. 62, Nr. 6, S. 3757–3767, 2015, doi: 10.1109/TIE.2015.2417501.
- [42] H. Wang und Y. Chen, „A robust fault detection and diagnosis strategy for multiple faults of VAV air handling units“, *Energy Build.*, Bd. 127, S. 442–451, 2016, doi: 10.1016/j.enbuild.2016.06.013.
- [43] H. Liao, W. Cai, F. Cheng, S. Dubey, und P. B. Rajesh, „An online data-driven fault diagnosis method for air handling units by rule and convolutional neural networks“, *Sensors*, Bd. 21, Nr. 13, 2021, doi: 10.3390/s21134358.
- [44] W. Y. Lee, J. M. House, und N. H. Kyong, „Subsystem level fault diagnosis of a building’s air-handling unit using general regression neural networks“, *Appl. Energy*, Bd. 77, Nr. 2, S. 153–170, 2004, doi: 10.1016/S0306-2619(03)00107-7.
- [45] B. Bezyan und R. Zmeureanu, „Detection and Diagnosis of Dependent Faults That Trigger False Symptoms of Heating and Mechanical Ventilation Systems Using Combined Machine Learning and Rule-Based Techniques“, *Energies*, 2022.
- [46] Z. Du, B. Fan, X. Jin, und J. Chi, „Fault detection and diagnosis for buildings and HVAC systems using combined neural networks and subtractive clustering analysis“, *Build. Environ.*, Bd. 73, S. 1–11, März 2014, doi:
-

- 10.1016/J.BUILDENV.2013.11.021.
- [47] H. Shahnazari, P. Mhaskar, J. M. House, und T. I. Salsbury, „Modeling and fault diagnosis design for HVAC systems using recurrent neural networks“, *Comput. Chem. Eng.*, Bd. 126, S. 189–203, Juli 2019, doi: 10.1016/j.compchemeng.2019.04.011.
- [48] V. Venkatasubramanian, R. Rengaswamy, S. N. Kavuri, und K. Yin, „A review of process fault detection and diagnosis part III: Process history based methods“, *Comput. Chem. Eng.*, Bd. 27, Nr. 3, S. 327–346, 2003, doi: 10.1016/S0098-1354(02)00162-X.
- [49] F. Stinner, A. Kornas, M. Baranski, und D. Müller, „Structuring building monitoring and automation system data“, in *The REHVA European HVAC Journal - August 2018*, REHVA, Hrsg. 2018, S. 10–15.
- [50] Z. Zheng, E. Yahia, E. Farazdaghi, R. El Meouche, F. Ababsa, und P. Beguery, „A data framework enabling BEM and BMS interoperability based on semantic web technologies and Brick ontology“, *Build. Simul. Conf. Proc.*, Bd. 18, S. 1521–1528, 2023, doi: 10.26868/25222708.2023.1366.
- [51] G. Haixiang, L. Yijing, J. Shang, G. Mingyun, H. Yuanyue, und G. Bing, „Learning from class-imbalanced data: Review of methods and applications“, *Expert Syst. Appl.*, Bd. 73, S. 220–239, 2017, doi: 10.1016/j.eswa.2016.12.035.
- [52] J. Wen und S. Li, „Tools for Evaluating Fault Detection and Diagnostic Methods for Air-Handling Units, ASHRAE Research Project 1312 Final Report“, Atlanta, GA, 2011.
- [53] T. Rist, M. Ihlenburg, und N. Réhault, „A mobile measurement solution for fault detection and diagnosis in buildings“, *IOP Conf. Ser. Earth Environ. Sci.*, Bd. 1085, Nr. 1, S. 12DUMMY, 2022, doi: 10.1088/1755-1315/1085/1/012010.
- [54] G. A. Benndorf, D. Wystrcil, und N. Réhault, „A fault detection system based on two complementary methods and continuous updates \*“, in *IFAC-PapersOnLine*, Jan. 2018, Bd. 51, Nr. 24, S. 353–358, doi: 10.1016/j.ifacol.2018.09.601.
- [55] The pandas development Team, „pandas-dev/pandas: Pandas“. Zenodo, 2020, doi: 10.5281/zenodo.3509134.
- [56] F. Pedregosa u. a., „Scikit-learn: Machine Learning in {P}ython“, *J. Mach. Learn. Res.*, Bd. 12, S. 2825–2830, 2011.
- [57] F. Chollet, „Keras“, *GitHub repository*. GitHub, 2015.
- [58] F. Sick, S. Dietz, G. Hillmann, M. Korolkow, und S. Rexroth, „Energieoptimiertes Bauen: Monitoring Plusenergie-Grundschule Hohen Neuendorf und IEA Task 41 (Solar Energy and Architecture): Schlussbericht: EnOB Forschung für Energieoptimiertes Bauen“, 2015. doi: 10.2314/GBV:847220060.
- [59] S. A. Klein u. a., „TRNSYS 18: A Transient System Simulation Program. Getting Started“, Bd. 1. Solar Energy Laboratory, S. 1–9, 2018, [Online]. Verfügbar unter: <http://www.trnsys.com/>.
- [60] S. A. Klein u. a., „TRNSYS 18: Mathematical Reference“, Bd. 4. Solar Energy Laboratory, S. 291–295, 2018, doi: 10.1108/978-1-78743-527-820181015.
- [61] Bitkom E. V., „Künstliche Intelligenz: Wirtschaftliche Bedeutung, gesellschaftliche Herausforderungen, menschliche Verantwortung“, *Bitkom e. V.*, S. 1–208, 2017, [Online]. Verfügbar unter: <https://www.dfki.de>.

## Liste der Veröffentlichungen

### Konferenzbeiträge

1. S. Dietz, F. Scholzen, N. Réhault, „Anwendung einer Kombination von KI-Methoden für die automatische Fehlererkennung und -diagnose an raumluftechnischen Anlagen“, *TGA-Kongress 2023 – Innovationen in der Gebäudetechnik, Forschung und Wissenschaft*, Berlin, Deutschland, 23-24 Mai, 2023.

### Konferenzbeiträge mit Peer-Review Verfahren

2. S. Dietz, F. Scholzen, N. Réhault, C. Dockendorf, „An easy to set up residual generator based on multilayer perceptron networks and Bayesian optimisation for the application in automated fault detection and diagnosis in building systems“, *Proceedings of the 18th IBPSA Conference*, Shanghai, China, 4-6 Sept., 2023, doi: 10.26868/25222708.2023.1240.
3. S. Dietz, F. Scholzen, N. Réhault, „Enhancing automated fault detection in building systems: A percentile-based scoring approach with dynamic tolerance range for residual evaluation“, *Konferenzband der BauSIM Wien 2024*, Wien, Österreich, 23.-26. Sept., 2024., ISBN: 978-3-200-10068-8
4. S. Dietz, N. Réhault, F. Scholzen, „Increasing transferability for automated fault detection and diagnosis in HVAC systems through a hybrid AI methodology“, *Sustainable Places 2024*, Luxemburg, Luxemburg, 23.-25. Sept., 2024.

### Anhang

A1.	Metriken zur Bewertung der Schätzqualität von ML-Modellen .....	164
A2.	Code-Beispiel für die Verwendung der entwickelten Python-Bibliothek.....	165
A3.	Schema der RLT-Anlage für die Aula in der Grundschule Hohen Neuendorf	167
A4.	Datenpunktliste für die Grundschule Hohen Neuendorf .....	167
A5.	Anteile der Betriebsmodi in den Datensätzen für das GSHN-Gebäude.....	169
A6.	Datenpunktliste für das Maison du Savoir.....	170
A7.	Anteile der Betriebsmodi in den Datensätzen für das MSA-Gebäude .....	172
A8.	Schemata der RLT-Anlagen in der anonymisierten Liegenschaft (ISC) .....	173
A9.	Datenpunktliste für die anonymisierte Liegenschaft (ISC).....	175
A10.	Anteile der Betriebsmodi in den Datensätzen für das ISC-Gebäude .....	178
A11.	Standardisierte Datenpunktbezeichnung .....	179
A12.	Ergebnisse zur Schätzung der Zulufttemperatur durch ein LSTM-Modell für unterschiedliche Modelkapazitäten .....	180
A13.	Ermittelte Perzentile für das Stellsignal der WRG der RLT-Anlage AUD 8 im MSA-Gebäude .....	180
A14.	Konfusions-Matrizen für die Fehlererkennung der RLT-Anlagen im GSHN-Gebäude.....	181
A15.	Konfusions-Matrizen für die Fehlererkennung der RLT-Anlagen im MSA-Gebäude.....	181
A16.	Skalierungsfaktoren der Fehlererkennung basierend auf der $L_2$ -Norm für den Vergleich mit der Scoring-Methode. ....	182
A17.	Lineare Diskriminanzanalyse für ausgewählte Symptom-Muster der RLT-Anlage AUD8 im MSA-Gebäude .....	182
A18.	Anzahl der Datensätze je Fehlertyp für die RLT-Anlagen in der GSHN .....	183
A19.	Observed Fehlermuster für die RLT-Anlagen in der GSHN .....	184
A20.	Anzahl der Datensätze je Fehlertyp für die RLT-Anlagen im MSA.....	187
A21.	Observed Fehlermuster für die RLT-Anlagen im MSA.....	189
A22.	Anzahl der Datensätze je Fehlertyp für die RLT-Anlagen im ISC-Gebäude ..	195

A23. Observierte Fehlermuster für die RLT-Anlagen im ISC-Gebäude .....	196
A24. Konfusions-Matrix der Fehlerisolation für die RLT-Anlage AUD8 im MSA-Gebäude .....	200

## A1. Metriken zur Bewertung der Schätzqualität von ML-Modellen

### Bestimmtheitsmaß ( $R^2$ )

$$R^2 = 1 - \frac{\sum_{t=1}^n (y(t) - \hat{y}(t))^2}{\sum_{t=1}^n (y(t) - \bar{y})^2} \quad (29)$$

$y(t)$ : *Observierter Wert zum Zeitpunkt  $t$*   
 $\hat{y}(t)$ : *Geschätzter Wert zum Zeitpunkt  $t$*   
 $\bar{y}$ : *Mittelwert der beobachteten Werte*

### Mittlerer absoluter Fehler (MAE)

$$MAE = 1/n \sum_{t=1}^n (y(t) - \hat{y}(t)) \quad (30)$$

$y(t)$ : *Observierter Wert zum Zeitpunkt  $t$*   
 $\hat{y}(t)$ : *Geschätzter Wert zum Zeitpunkt  $t$*   
 $n$ : *Anzahl der beobachteten Werte*

### Mittlerer quadratischer Fehler (MSE)

$$MSE = 1/n \sum_{t=1}^n (y(t) - \hat{y}(t))^2 \quad (31)$$

$y(t)$ : *Observierter Wert zum Zeitpunkt  $t$*   
 $\hat{y}(t)$ : *Geschätzter Wert zum Zeitpunkt  $t$*   
 $n$ : *Anzahl der beobachteten Werte*

### Wurzel des mittleren quadratischen Fehlers (RMSE):

$$RMSE = \sqrt{1/n \sum_{t=1}^n (y(t) - \hat{y}(t))^2} \quad (32)$$

$y(t)$ : *Observierter Wert zum Zeitpunkt  $t$*   
 $\hat{y}(t)$ : *Geschätzter Wert zum Zeitpunkt  $t$*   
 $n$ : *Anzahl der beobachteten Werte*

## Kreuzentropie (H)

$$H(p, q) = -1/n \sum_{t=1}^n \left[ \sum_{j=1}^m q_j(t) * \log(p_j(t)) \right] \quad (33)$$

- $q_j(t)$ : *Observierter (codierte) Wert der j-ten Klasse zum Zeitpunkt t*  
 $p_j(t)$ : *Geschätzter (codierter) Wert der j – tne Klasse zum Zeitpunkt t*  
 $n$ : *Anzahl der observierten Werte*  
 $m$ : *Anzahl der kategorischen Klassen*

## A2. Code-Beispiel für die Verwendung der entwickelten Python-Bibliothek

.....

Beispiel Python-Code zur Nutzung der entwickelten FED-Bibliothek

Hinweise:

- Der nachstehende Programmcode soll die Nutzung der Python Bibliothek lediglich veranschaulichen und ist in der abgebildeten Form nicht lauffähig.
- Um eine einfache Anwendung der Methodik zu gewährleisten, sind in den einzelnen Teilschritten Standardwerte in einem Dictionary (bswp. sys.fdd.resgen.settings) hinterlegt und können individuell angepasst werden.

.....

.....

Import der verwendeten Python-Bibliotheken

.....

```
#
import fdd.db.dataimport as dataimport
from fdd.db.metaimport import MetaImport
from fdd.db.hdf5 import Hdf5
from fdd.sys.system import System
```

.....

Import der Rohdaten eines Projektes

.....

```
# Import der Meta-Daten aus einem Excel Template
metaimp = MetaImport('meta/GSHN_SysMeta.xlsx')
# Import der Messdaten aus ASCII-Text-Dateien
importer = dataimport.Importer('.', 'GSHN', 'data/import',
                               hdf5file='hdf5/data.h5',
                               filetype='linebyline',
                               timezone='Europe/Berlin',
                               timezone_origin='utc',
                               ...)
importer.update_hdf5file(overwrite=False)
```

.....

Aufbereitung der Rohdaten eines Systems

.....

```
# Öffnen der Datenbank
h5 = Hdf5('hdf5/data.h5')
h5.open()
# System-Objekt erstellen und Informationen aus der Datenbank laden
sys = System(h5, name='ahu fla')
```

## Anhang

---

```
# Rohdaten Verarbeiten und in ein einheitliches Zeitintervall bringen
sys.data.process_raw_data(path='data/raw', interval=300, save=True)
# Zusätzliche Features berechnen (z.B. Temperaturdifferenzen)
sys.features.add(update_hdf5=True)

.....

Zeitbereiche für das Modelltraining und die Auswertung definieren
.....

periods = {'training' : ('2015-01-01','2015-12-31'),
          'validation' : ('2016-01-01','2016-12-31'),
          'testing' : ('2017-01-01','2017-12-31'),
          'prediction' : ('2015-01-01','2019-05-29')}
sys.meta.add_periods(periods,update_hdf5=True)

.....

Diagramme erstellen
.....

# Anteile der Betriebsmodi an den Datensätzen
labels, periods = sys.meta.get_periods(return_list=True)
sys.plot.operating_mode_rate(periods, labels, plt_type='pie')
# Zeitreihendiagramme der verarbeiteten Daten
sys.plot.set_timerange('2015-01', '2015-12')
sys.plot.ts_data(save=True, name='sysdata_2015',
                 typefilters=['counter','power','dT','efficiency'])

.....

Auswahl der Eingangs- und Zielvariablen für die Modellerstellung
.....

period = sys.meta.get_periods()['training']
featurenames = sys.features.select(timeperiod=period)
targets = sys.features.get_targets()

.....

Residuen-Generator trainieren
.....

# Residuen-Generator Objekt erzeugen sowie
# Eingangs- und Zielgrößen definieren
sys.fdd.resgen.create(featurenames, targets)
# Modelltraining durchführen
sys.fdd.resgen.fit()
# Modelle speichern
sys.fdd.resgen.save_results()

.....

Residuen evaluieren und Fehlererkennung durchführen
.....

sys.fdd.resgen.evaluate(method='linear')
sys.fdd.resgen.fault_detection(threshold=1.5)
# Evaluation der Performance
sys.fdd.resgen.fd_performance()
# Report der Fehlererkennung erstellen
sys.fdd.resgen.report()

.....

Datenbank schließen
.....

h5.close()
```



### A3. Schema der RLT-Anlage für die Aula in der Grundschule Hohen Neuendorf




Abbildung 80: Prinzipschema der RLT-Anlage für die Aula in der Grundschule Hohen Neuendorf.

### A4. Datenpunktliste für die Grundschule Hohen Neuendorf

Tabelle 29: Verfügbarkeit der Betriebsdaten für die Lüftungsanlagen der Grundschule Hohen Neuendorf und deren Datenpunktbezeichnung.

Datenpunktbezeichnung	Beschreibung	Einheit	Lüftungsanlage					
			SPO	AUL	FLA	FLB	FLC	FAC
supa_meat	Zulufttemperatur	°C	✓	✓	✓	✓	✓	✓
supa_meahr	Relative Zuluftfeuchte	%	-	✓	-	-	-	-
exha_meat	Ablufttemperatur	°C	✓	✓	✓	✓	✓	✓
exha_meahr	Relative Abluftfeuchte	%	-	✓	-	-	-	-
exhao_meat	Fortlufttemperatur	°C	✓	✓	✓	✓	✓	✓
oa_meat	Außenlufttemperatur im Luftkanal	°C	✓	✓	✓	✓	✓	✓
oa_meahr	Relative Außenluftfeuchte	%	-	✓	-	-	-	-
supa_meavp	Zuluftvolumenstrom (Ventilatoransteuerung)	m³/h	✓	✓	✓	✓	✓	✓
exha_meavp	Abluftvolumenstrom (Ventilatoransteuerung)	m³/h	✓	✓	✓	✓	✓	✓

## Anhang

Datenpunkt- bezeichnung	Beschreibung	Einheit	Lüftungsanlage					
			SPO	AUL	FLA	FLB	FLC	FAC
hc_supw_mea_t	Vorlauftemperatur des Heizregisters	°C	✓	✓	✓	✓	✓	✓
hc_retw_mea_t	Rücklauftemperatur des Heizregisters	°C	✓	✓	✓	✓	✓	✓
hc_ctrv	Stellsignal für das Regelventil des Heizregisters (100% = Ventil auf)	%	✓	✓	✓	✓	✓	✓
hrc_byp_ctrlsig	Stellsignal für den WRG-Bypass (100% = Bypass aktiv)	%	✓	✓	✓	✓	✓	✓
hc_retw_mea_vp	Volumenstrom im hydraulischen Heizregisterkreislauf	l/h	✓	✓	✓	✓	✓	✓
supa_recirc_ctrlsig	Stellsignal für die Umluftklappe (100% = Umluft)	%	✓	✓	✓	✓	✓	✓
adc_pu_ctrlsig	Stellsignal der Befeuchterpumpe für die adiabate Kühlung	-	-	✓	-	-	-	-
ahu_mode_stat	Betriebsstatus der Anlage (0 = Aus, 1 = 1. Stufe, 2 = 2. Stufe)	-	✓	✓	✓	✓	✓	✓
hc_mea_eh	Wärmemenge des Heizregisters (kumuliert)	kWh	✓	✓	✓	✓	✓	✓
hc_mea_ph	Wärmeleistung des Heizregisters	kW	✓	✓	✓	✓	✓	✓
ahu_mea_el	Elektrische Energiebezug der Anlage (kumuliert)	kWh	✓	✓	✓	✓	✓	✓
ahu_mea_pel	Elektrische Leistungsbezug der Anlage	kW	✓	✓	✓	✓	✓	✓

**A5. Anteile der Betriebsmodi in den Datensätzen für das GSHN-Gebäude**




Abbildung 81: Anteile der Betriebsmodi für die RLT-Anlage FLA im GSHN-Gebäude an den Datensätzen für das Training, die Validierung und das Testen




Abbildung 82: Anteile der Betriebsmodi für die RLT-Anlage FLC im GSHN-Gebäude an den Datensätzen für das Training, die Validierung und das Testen




Abbildung 83: Anteile der Betriebsmodi für die RLT-Anlage FA im GSHN-Gebäude an den Datensätzen für das Training, die Validierung und das Testen




Abbildung 84: Anteile der Betriebsmodi für die RLT-Anlage AULA im GSHN-Gebäude an den Datensätzen für das Training, die Validierung und das Testen

## A6. Datenpunktliste für das Maison du Savoir

Tabelle 30: Erfasste Betriebsdaten für die Lüftungsanlagen im Gebäude Maison du Savoir deren Datenpunktbezeichnung und Intervall der Datenspeicherung.

Datenpunktbezeichnung	Beschreibung	Einheit	Intervall
supa_mea_t	Zulufttemperatur	°C	300s
supa_mea_rh	Relative Luftfeuchte der Zuluft	%	300s
fan_vsd_supa	Ventilatoransteuerung Zuluft (0-100%)	%	300s
oa_mea_rh	Relative Außenluftfeuchte (im Luftkanal)	%	300s
oa_mea_t	Außenlufttemperatur (im Luftkanal)	°C	1800s
ra_mea_t	Raumtemperatur	°C	900s
exha_mea_rh	Abluftfeuchte	%	300s
exha_mea_t	Ablufttemperatur	°C	300s
fan_vsd_exha	Ventilatoransteuerung Abluft (0-100%)	%	300s
adc_pu_ctrlsig	Ansteuerung der Umwälzpumpe für die adiabate Kühlung (0/1)	-	event
damp_all_ctrlsig	Stellsignal der Umluft- und Außenluftklappen (0-100%)	%	300s
hrc_whl_ctrlsig	Ansteuerung des Wärmerückgewinnungsrades (0-100%)	%	300s
fil_exha_stat	Warnmeldung Abluftfilter (0/1)	-	event
fil_oa_stat	Warnmeldung Außenluftfilter (0/1)	-	event
fil_supa_stat	Warnmeldung Zuluftfilter (0/1)	-	event

Datenpunkt- bezeichnung	Beschreibung	Einheit	Intervall
hc_pu_ctrlsig	Ansteuerung der Pumpe im hydraulischen Kreislauf des Heizregisters (0/1)	-	event
ahu_mode_stat	Betriebsstatus der Anlage (1/2/3/4)	-	event
ra_sev_t_summer	Raumsolltemperatur im Kühlbetrieb	°C	300s
ra_sev_t_winter	Raumsolltemperatur im Heizbetrieb	°C	300s
supa_ahrc_mea_t	Zulufttemperatur nach der Wärmerückgewinnung	°C	300s
ex- ha_aadc_mea_t	Ablufttemperatur nach der adiabaten Kühlung	°C	300s
hc_retw_mea_t	Rücklauftemperatur im hydraulischen Kreislauf des Heizregisters	°C	300s
adc_val_fill_ctrlsig	Freigabe für das Ventil zur Befüllung der adiabaten Kühlung (0/1)	-	300s
hc_ctrv	Stellsignal für das Regelventil im hydraulischen Kreislauf des Heizregisters (0-100%)	%	300s
adc_val_flush_ctrlsig	Signal zur Spülung des adiabaten Kühlsystems (0/1)	-	300s
hc_mea_eh*	Wärmemenge des Heizregisters (kumuliert)	kWh	900s
hc_mea_vc*	Wassermenge des Heizregisters (kumuliert)	m <sup>3</sup>	900s
hc_mea_ph*	Wärmeleistung des Heizregisters	kW	900s
adc_dcw_mea_vc*	Wassermenge der adiabaten Kühlung	m <sup>3</sup>	900s
fan_mea_el*	Elektrischer Energieverbrauch der Ventilatoren	kWh	600s
fan_mea_pel*	Elektrische Leistungsaufnahme der Ventilatoren	kW	600s
exha_mea_co2	CO <sub>2</sub> Konzentration der Abluft	ppm	300s
ra_mea_co2	CO <sub>2</sub> -Konzentration der Raumluft	ppm	300s

\* Nur für die RLT-Anlagen AUD2 und AUD7 verfügbar.

**A7. Anteile der Betriebsmodi in den Datensätzen für das MSA-Gebäude**




Abbildung 85: Anteile der Betriebsmodi für die RLT-Anlage AUD2 im MSA-Gebäude an den Datensätzen für das Training, die Validierung und das Testen




Abbildung 86: Anteile der Betriebsmodi für die RLT-Anlage AUD4 im MSA-Gebäude an den Datensätzen für das Training, die Validierung und das Testen




Abbildung 87: Anteile der Betriebsmodi für die RLT-Anlage AUD7 im MSA-Gebäude an den Datensätzen für das Training, die Validierung und das Testen




Abbildung 88: Anteile der Betriebsmodi für die RLT-Anlage AUD11 im MSA-Gebäude an den Datensätzen für das Training, die Validierung und das Testen

### A8. Schemata der RLT-Anlagen in der anonymisierten Liegenschaft (ISC)

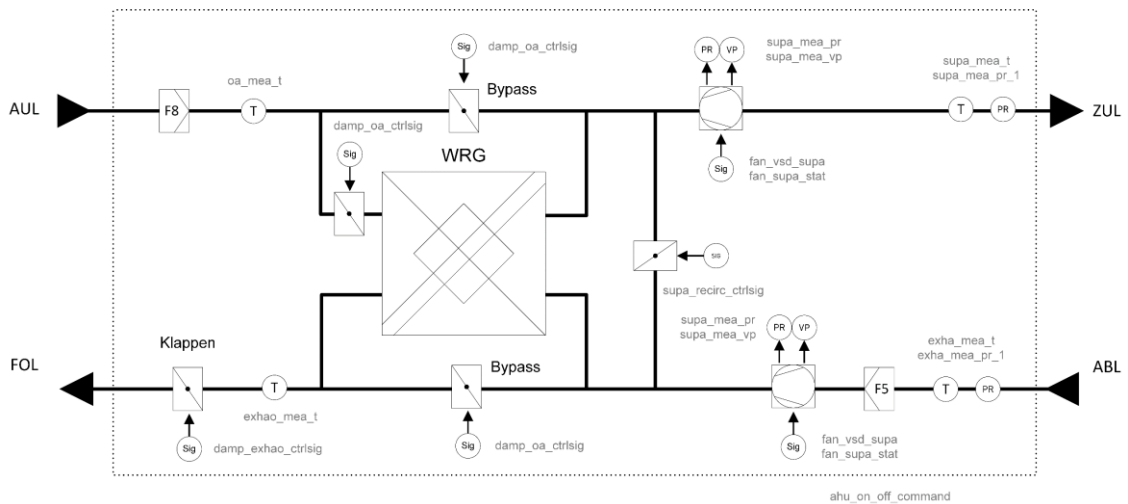


Abbildung 89: Prinzipschema der RLT-Anlage für die RLT-Anlagen CTA01 und CTA03 in der anonymisierten Liegenschaft (ISC).




Abbildung 90: Prinzipschema der RLT-Anlage für die RLT-Anlage CTA08 in der anonymisierten Liegenschaft (ISC).




Abbildung 91: Prinzipschema der RLT-Anlage für die RLT-Anlage CTA17 in der anonymisierten Liegenschaft (ISC).



## A9. Datenpunktliste für die anonymisierte Liegenschaft (ISC)

Tabelle 31: Verfügbarkeit der Betriebsdaten für die Lüftungsanlagen der anonymisierten Liegenschaft.

Datenpunkt- bezeichnung	Beschreibung	Ein- heit	Inter- vall	Lüftungsanlage				
				CTA 01	CTA 02	CTA 04	CTA 08	CTA 17
ahu_auto_ mode_stat	Automatik / Handbetrieb	-	1200s	✓	✓	✓	✓	✓
ahu_on_off_ command	Betriebszustand (Ein/Aus)	-	1200s	✓	✓	✓	✓	✓
aohood_supa_ sev_t	Sollwert für die Zuluft im Experimentierbereich	°C	event	-	-	-	✓	-
aohood_exha_ stat_1	Status der Abzugshaube im Experimentierbereich	-	1800s	-	-	-	✓	-
aohood_exha_ stat_2	Status Abzugshaube Labor 2	-	1800s	-	-	-	✓	-
damp_exhao_ ctrlsig	Stellsignal für die Fortluft- klappe	%	1200s	✓	-	✓	✓	-
damp_oa_ctrlsig	Stellsignal für die Außen- luftklappen	%	event	✓	✓	✓	✓	✓
damp_recirc_ ctrlsig	Stellsignal für die Umluft- klappe	%	event	-	✓	-	-	✓
damp_recirc_ sev_ctrlsig	Sollwert für das Stellsignal der Umluftklappe	%	900s	-	✓	-	-	✓
exha_mea_co2	CO2-Konzentration in der Abluft	ppm	1800s	-	✓	-	-	-
exha_mea_pr	Förderdruck Abluftventilator	Pa	event	✓	✓	✓	✓	✓
exha_mea_pr_1	Zusätzlicher Drucksensor im Abluftkanal	Pa	event	-	-	-	✓	✓
exha_mea_pr_2	Zusätzlicher Drucksensor im Abluftkanal	Pa	event	-	-	-	✓	-
exha_mea_t	Ablufttemperatur	°C	event	✓	✓	✓	✓	✓
exha_mea_vp	Abluftvolumenstrom	m³/h	event	✓	✓	✓	✓	✓
exha_sev_ max_vp	Maximaler Sollwert für den Abluftvolumenstrom	m³/h	900s	-	-	-	✓	✓
exha_sev_ min_vp	Minimaler Sollwert für den Abluftvolumenstrom	m³/h	900s	-	✓	-	-	-

## Anhang

Datenpunkt- bezeichnung	Beschreibung	Ein- heit	Inter- vall	Lüftungsanlage				
				CTA 01	CTA 02	CTA 04	CTA 08	CTA 17
exha_sev_pr	Sollwert für den Druck im Abluftkanal	Pa	900s	-	-	-	✓	✓
exha_sev_t	Sollwert für die Ablufttemperatur	°C	900s	-	✓	-	✓	-
exha_sev_vp	Sollwert für den Abluftvolumenstrom	m³/h	event	✓	✓	✓	-	-
exha_thr_high_co2	Oberer Grenzwert für CO2-Konzentration	ppm	1800s	-	✓	-	-	-
exha_thr_low_co2	Unterer Grenzwert für die CO2-Konzentration in der Abluft	ppm	1800s	-	✓	-	-	-
exhao_mea_t	Fortlufttemperatur	°C	event	✓	✓	✓	✓	-
fan_exha_stat	Status des Abluftventilators (0/1)	-	event	✓	✓	✓	✓	✓
fan_supa_stat	Betriebsstatus Zuluftventilator (0/1)	-	1800s	✓	✓	✓	✓	✓
fan_vsd_exha	Ventilatoransteuerung Abluft (0-100%)	%	event	✓	✓	✓	✓	✓
fan_vsd_supa	Ventilatoransteuerung Zuluft (0-100%)	%	1800s	✓	✓	✓	✓	✓
hc_ctrv	Stellsignal für das Regelventil im hydraulischen Kreislauf des Heizregisters	%	event	-	✓	-	✓	✓
hc_mea_eh	Wärmemenge des Heizregisters (kumuliert)	kWh	3600s	-	✓	-	✓	✓
hc_mea_ph	Wärmeleistung des Heizregisters	kW	3600s	-	✓	-	✓	✓
hc_pu_ctrlsig	Steuersignal für die Pumpe im hydraulischen Kreislauf des Heizregisters	-	event	-	✓	-	✓	✓
hc_pu_mea_el	Leistungsaufnahme der Heizregisterpumpe	kWh	3600s	-	✓	-	✓	✓
hc_pu_mea_pel	Elektrische Leistungsaufnahme der Heizregisterpumpe	kW	900s	-	✓	-	✓	✓

Datenpunkt- bezeichnung	Beschreibung	Ein- heit	Inter- vall	Lüftungsanlage				
				CTA 01	CTA 02	CTA 04	CTA 08	CTA 17
hc_retw_actrv_ mea_t	Rücklauf­temperatur nach Regelventil im hydraulischen Kreislauf des Heizre- gisters	°C	900s	-	✓	-	✓	✓
hc_retw_actrv_ mea_vp	Volumenstrom vor dem Re- gelventil im hydraulischen Kreislauf des Heizregisters	m³/h	3600s	-	✓	-	✓	✓
hc_retw_mea_t	Rücklauf­temperatur im hyd- raulischen Kreislauf des Heizregisters	°C	event	-	✓	-	✓	✓
hc_retw_mea_v p	Volumenstrom des Heizre- gisters	m³/h	3600s	-	✓	-	✓	✓
hc_supw_bctrv_ mea_t	Vorlauf­temperatur vor dem Regelventil im hydraulischen Kreislauf des Heizre- gisters	°C	event	-	✓	-	✓	✓
hrc_byp_ctrlsig	Stellsignal für den Bypass der WRG	%	1800s	✓	-	✓	✓	-
hrc_whl_ctrlsig	Ansteuerung für den Rotati- onswärmetauscher	%	1800s	-	✓	-	-	✓
oa_mea_t	Außenlufttemperatur (im Luftkanal)	°C	event	✓	✓	✓	✓	✓
supa_mea_pr	Förderdruck Zuluftventilator	Pa	1800s	✓	✓	✓	✓	✓
supa_mea_ pr_1	Zusätzlicher Drucksensor im Zuluftkanal	Pa	event	-	-	-	✓	✓
supa_mea_ pr_2	Zusätzlicher Drucksensor im Zuluftkanal	Pa	1800s	-	-	-	✓	-
supa_mea_t	Zulufttemperatur	°C	event	✓	✓	✓	✓	✓
supa_mea_vp	Zuluftvolumenstrom	m³/h	1800s	✓	✓	✓	✓	✓
supa_sev_ max_t	Maximaler Sollwert für die Zulufttemperatur	°C	900s	-	✓	-	✓	-
supa_sev_ max_vp	Maximaler Sollwert für den Zuluftvolumenstrom	m³/h	900s	-	✓	-	✓	✓
supa_sev_ min_t	Minimaler Sollwert für die Zulufttemperatur	°C	900s	-	✓	-	✓	-
supa_sev_ min_vp	Minimaler Sollwert für den Zuluftvolumenstrom	m³/h	900s	-	✓	-	-	-

Datenpunkt- bezeichnung	Beschreibung	Ein- heit	Inter- vall	Lüftungsanlage				
				CTA 01	CTA 02	CTA 04	CTA 08	CTA 17
supa_sev_pr	Sollwert für den Zuluftdruck	Pa	900s	-	-	-	-	✓
supa_sev_t	Sollwert für die Zulufttemperatur	°C	900s	✓	✓	✓	-	✓
supa_sev_vp	Sollwert für den Zuluftvolumenstrom	m³/h	1800s	✓	✓	✓	-	

**A10. Anteile der Betriebsmodi in den Datensätzen für das ISC-Gebäude**




Abbildung 92: Anteile der Betriebsmodi für die RLT-Anlage CTA01 im ISC-Gebäude an den Datensätzen für das Training, die Validierung und das Testen




Abbildung 93: Anteile der Betriebsmodi für die RLT-Anlage CTA03 im ISC-Gebäude an den Datensätzen für das Training, die Validierung und das Testen




Abbildung 94: Anteile der Betriebsmodi für die RLT-Anlage CTA17 im ISC-Gebäude an den Datensätzen für das Training, die Validierung und das Testen

### A11. Standardisierte Datenpunktbezeichnung

In dieser Arbeit wird hierzu eine projekt- oder gebäudespezifische Sensorliste verwendet. Diese Liste beinhaltet neben einer textlichen Beschreibung des Datenpunktes sogenannte Metadaten wie Sensortyp, Einheit, Messintervall, Systemzugehörigkeit, etc. und generiert aus diesen Angaben Standard Datenpunktname nachfolgender Systematik:

„Gebäude\_Zone\_System\_Subsystem1\_Subsystem2\_Medium\_Position\_Art\_Datenpunkt“

Beispielsweise ergibt sich für die gemessene Ablufttemperatur (EXHA, MEA, T) vor der Wärmerückgewinnung (B.HRC) einer Lüftungsanlage (AHU) in der Gebäudezone Bauteil B (BT.B) der Grundschule Hohen Neuendorf (GSHN) folgende Bezeichnung:

„GSHN\_BT.B\_AHU.flb\_\_EXHA\_B.HRC\_MEA\_T“

### A12. Ergebnisse zur Schätzung der Zulufttemperatur durch ein LSTM-Modell für unterschiedliche Modelkapazitäten




Abbildung 95: Metriken (MAE, RMSE) für unterschiedliche Modellkapazitäten eines Long-Short-Term-Memory (LSTM) Models mit ReLU-Aktivierungsfunktion zur Schätzung der Zulufttemperatur (GSHN, FLA).

### A13. Ermittelte Perzentile für das Stellsignal der WRG der RLT-Anlage AUD 8 im MSA-Gebäude

Tabelle 32: Ermittelte Perzentile für das Stellsignal der WRG der RLT-Anlage AUD 8 im MSA-Gebäude.

	Keine Luftbehandlung	Heizbetrieb	Heizbetrieb mit Umluftanteil	Kühlbetrieb
<b>Median</b>	0,00	0,02	0,04	0,05
<b><math>p_{1,unten}</math></b>	-0,38	0,01	-0,47	-0,34
<b><math>p_{1,oben}</math></b>	0,37	0,06	0,53	0,61
<b><math>p_{2,unten}</math></b>	-0,61	0,00	-0,53	-0,45
<b><math>p_{2,oben}</math></b>	0,51	0,15	0,55	0,64
<b><math>p_{3,unten}</math></b>	-0,67	-0,24	-0,55	-0,52
<b><math>p_{3,oben}</math></b>	0,77	0,33	0,55	0,71
<b><math>p_{4,unten}</math></b>	-0,77	-0,39	-0,56	-0,55
<b><math>p_{4,oben}</math></b>	0,92	0,44	0,56	0,83
<b><math>p_{5,unten}</math></b>	-0,84	-0,60	-0,56	-0,56
<b><math>p_{5,oben}</math></b>	0,98	0,53	0,56	0,91

#### A14. Konfusions-Matrizen für die Fehlererkennung der RLT-Anlagen im GSHN-Gebäude




Abbildung 96: Konfusion-Matrix für die Fehlererkennung im Testzeitraum der RLT-Anlagen FLA (links) und FLB (rechts) im GSHN-Gebäude. Angegeben sind die absoluten und relativen Anteile der Klassen am Gesamtdatensatz. Die Farbgebung der Kacheln zeigt den Anteil der wahren Klasse ( $FS_{wahr}$ ).

#### A15. Konfusions-Matrizen für die Fehlererkennung der RLT-Anlagen im MSA-Gebäude




Abbildung 97: Konfusion-Matrix für die Fehlererkennung im Testzeitraum der RLT-Anlagen AUD7 (links) und AUD8 (rechts) im MSA-Gebäude. Angegeben sind die absoluten und relativen Anteile der Klassen am Gesamtdatensatz. Die Farbgebung der Kacheln zeigt den Anteil der wahren Klasse ( $FS_{wahr}$ ).

**A16. Skalierungsfaktoren der Fehlererkennung basierend auf der L2-Norm für den Vergleich mit der Scoring-Methode.**

Tabelle 33: Skalierungsfaktoren (f) für die Anpassung der Sensitivität der L2-Norm basierten FE.

GSHN		MSA		ISC	
FLA	12,0	AUD2	4,4	CTA01	3,0
FLB	9,5	AUD4	7,0	CTA02	4,5
FLC	9,5	AUD7	9,5	CTA03	5,0
FA	8,0	AUD8	7,0	CTA08	8,0
AULA	5,8	AUD9	7,0	CTA17	3,0
SPO	5,5	AUD11	5,5		

**A17. Lineare Diskriminanzanalyse für ausgewählte Symptom-Muster der RLТ-Anlage AUD8 im MSA-Gebäude**




Abbildung 98: Lineare Diskriminanzanalyse für ausgewählte Symptom-Muster der RLТ-Anlage AUD8 im MSA-Gebäude. Zur Veranschaulichung des Klassifizierungspotentials der Symptom-Muster in Form von Punktwolken werden die Residuen in einen zweidimensionalen Merkmalsraum transformiert.



**A18. Anzahl der Datensätze je Fehlertyp für die RLT-Anlagen in der GSHN**




Abbildung 99: Anzahl der Datensätze je Fehlertyp im Betrieb der RLT-Anlagen in der GSHN für den gesamten Betrachtungszeitraum.




Abbildung 100: Anzahl der Datensätze je Fehlertyp im Betrieb der RLT-Anlagen in der GSHN für den gesamten Trainingszeitraum.




Abbildung 101: Anzahl der Datensätze je Fehlertyp im Betrieb der RLT-Anlagen in der GSHN für den Testzeitraum.

**A19. Observierte Fehlermuster für die RLT-Anlagen in der GSHN**

**FLA**






Abbildung 102: Observierte Fehlermuster für die RLT-Anlage FLA in der GSHN.

FLB


flb: Erwärmung der Zone über Außenluft (Sommer)




flb: Niedrige Zu- und Ablufttemperatur




flb: Niedrige Zulufttemperatur



flb: Heizen und WRG Bypass aktiv



flb: Heizbetrieb ohne Luftvolumenstrom



flb: Keine Heizleistung bei geöffnetem HR-Ventil




Abbildung 103: Observierte Fehlermuster für die RLT-Anlage FLB in der GSHN.

**FLC**

flc: Keine Heizleistung bei geöffnetem HR-Ventil




Abbildung 104: Observierte Fehlermuster für die RLT-Anlage FLC in der GSHN.

**FA**

fa: Keine Heizleistung bei geöffnetem HR-Ventil






Abbildung 105: Observierte Fehlermuster für die RLT-Anlage FA in der GSHN.

**AULA**


aula: Erwärmung der Zone über Außenluft (Sommer)



aula: Asynchroner Betrieb der Ventilatoren



aula: Gleichzeitiges Heizen und adiabates Kühlen



aula: Keine Heizleistung bei geöffnetem HR-Ventil




Abbildung 106: Observierte Fehlermuster für die RLT-Anlage AULA in der GSHN.

SPO

spo: Heizbetrieb ohne Wärmerückgewinnung (Rad)

spo: Keine Heizleistung bei geöffnetem HR-Ventil




Abbildung 107: Observierte Fehlermuster für die RLT-Anlage SPO in der GSHN.

A20. Anzahl der Datensätze je Fehlertyp für die RLT-Anlagen im MSA

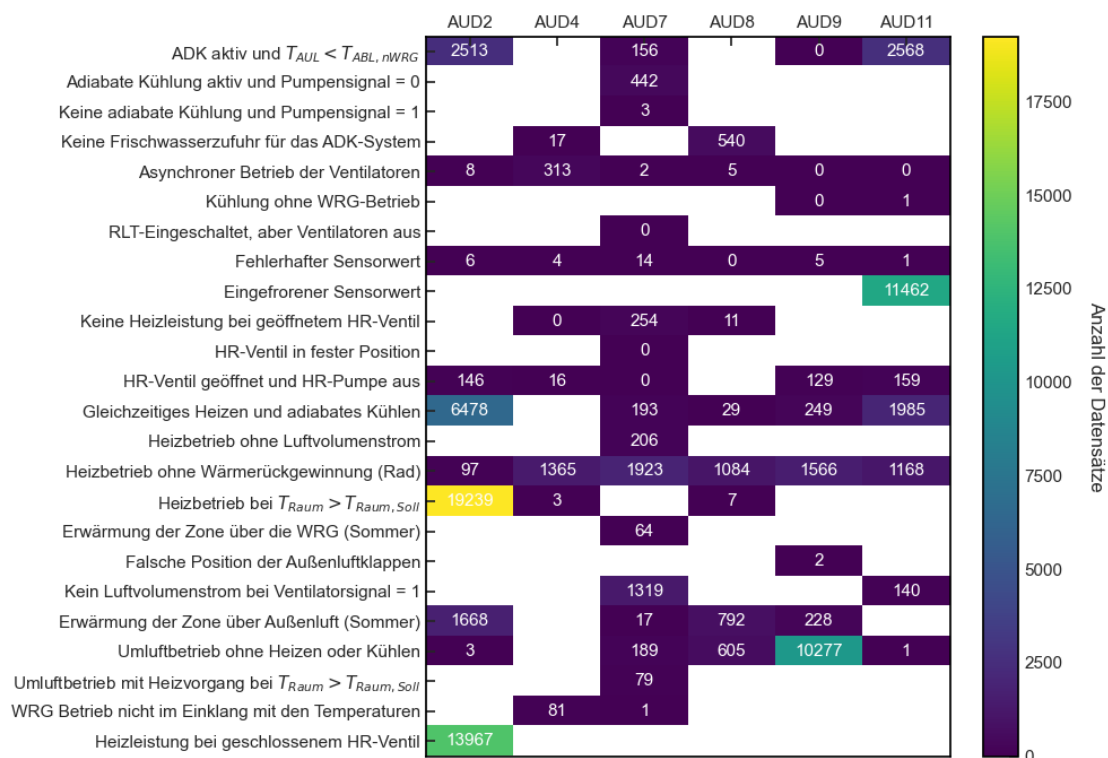


Abbildung 108: Anzahl der Datensätze je Fehlertyp im Betrieb der RLT-Anlagen MSA-Gebäude für den gesamten Betrachtungszeitraum.

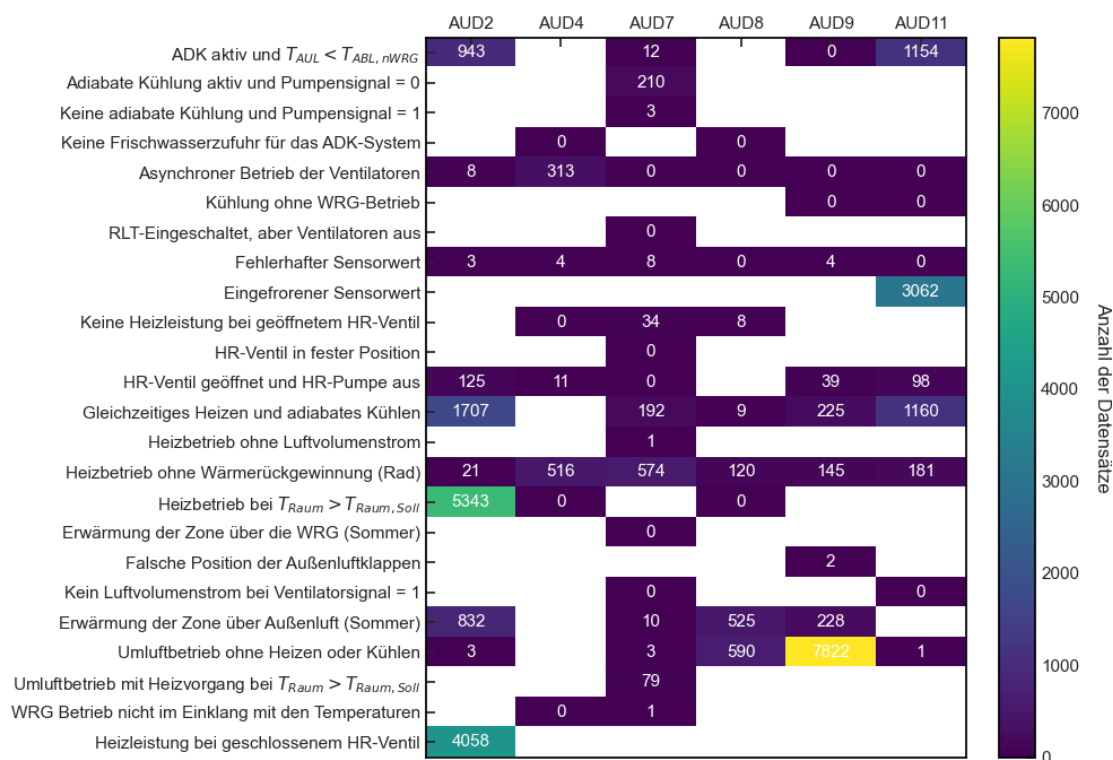


Abbildung 109: Anzahl der Datensätze je Fehlertyp im Betrieb der RLT-Anlagen im MSA-Gebäude für den Trainingszeitraum.

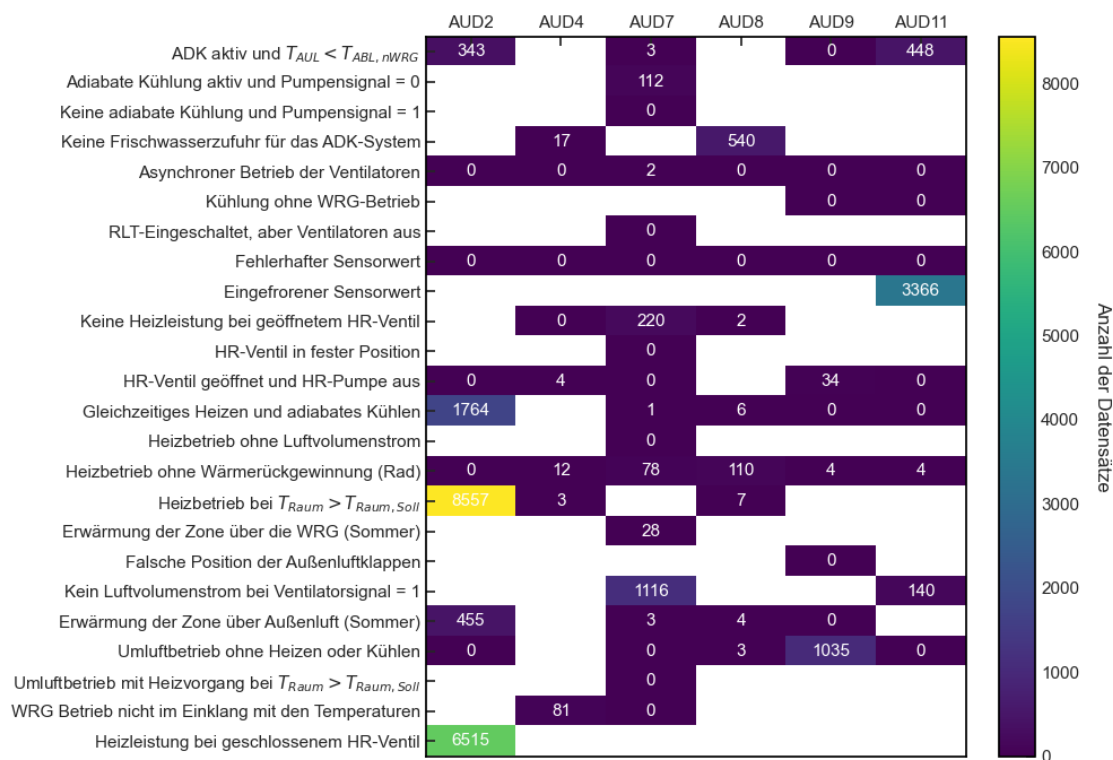



Abbildung 110: Anzahl der Datensätze je Fehlertyp im Betrieb der RLT-Anlagen im MSA Gebäude für den Testzeitraum.


**A21. Observierte Fehlermuster für die RLT-Anlagen im MSA**

**AUD2**


aud2: Heizleistung bei geschlossenem HR-Ventil




aud2: Umluftbetrieb ohne Heizen oder Kühlen




aud2: Erwärmung der Zone über Außenluft (Sommer)



aud2: Heizbetrieb bei  $T_{Raum} > T_{Raum, soll}$



aud2: Heizbetrieb ohne Wärmerückgewinnung (Rad)



aud2: Gleichzeitiges Heizen und adiabates Kühlen




Abbildung 111: Observierte Fehlermuster für die RLT-Anlage AUD2 im MSA.




Abbildung 112: Observierte Fehlermuster für die RLT-Anlage AUD2 im MSA.

AUD4





Abbildung 113: Observierte Fehlermuster für die RLT-Anlage AUD4 im MSA.




AUD7


aud7: Umluftbetrieb ohne Heizen oder Kühlen




aud7: Erwärmung der Zone über Außenluft (Sommer)




aud7: Kein Luftvolumenstrom bei Ventilatorsignal = 1



aud7: Heizbetrieb ohne Wärmerückgewinnung (Rad)



aud7: Heizbetrieb ohne Luftvolumenstrom



aud7: Gleichzeitiges Heizen und adiabates Kühlen






Abbildung 114: Observierte Fehlermuster für die RLT-Anlage AUD7 im MSA.


aud7: Keine Heizleistung bei geöffnetem HR-Ventil



aud7: Fehlerhafter Sensorwert



aud7: Adiabate Kühlung aktiv und Pumpensignal = 0



aud7: ADK aktiv und  $T_{AUL} < T_{ABL, nWRG}$





Abbildung 115: Observierte Fehlermuster für die RLT-Anlage AUD7 im MSA.

### AUD8

aud8: Umluftbetrieb ohne Heizen oder Kühlen



aud8: Erwärmung der Zone über Außenluft (Sommer)



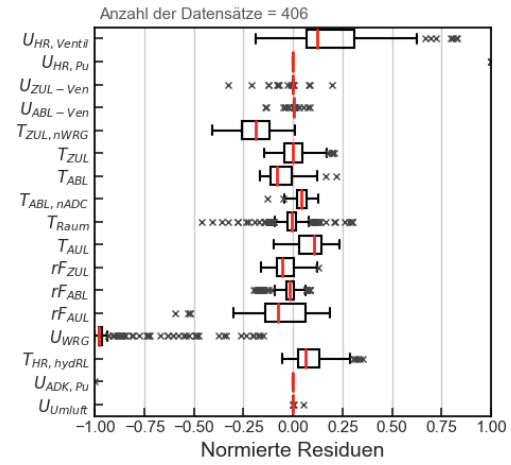


Abbildung 116: Observierte Fehlermuster für die RLT-Anlage AUD8 im MSA.


aud8: Heizbetrieb bei  $T_{Raum} > T_{Raum,Soll}$




aud8: Heizbetrieb ohne Wärmerückgewinnung (Rad)




aud8: Gleichzeitiges Heizen und adiabates Kühlen



aud8: Keine Heizleistung bei geöffnetem HR-Ventil



aud8: Asynchroner Betrieb der Ventilatoren



aud8: Keine Frischwasserzufuhr für das ADK-System






Abbildung 117: Observierte Fehlermuster für die RLT-Anlage AUD8 im MSA.

**AUD9**


aud9: Umluftbetrieb ohne Heizen oder Kühlen



aud9: Heizbetrieb ohne Wärmerückgewinnung (Rad)



aud9: Gleichzeitiges Heizen und adiabates Kühlen



aud9: HR-Ventil geöffnet und HR-Pumpe aus





Abbildung 118: Observierte Fehlermuster für die RLT-Anlage AUD9 im MSA.

**AUD11**

aud11: Kein Luftvolumenstrom bei Ventilatorsignal = 1



aud11: Heizbetrieb ohne Wärmerückgewinnung (Rad)





Abbildung 119: Observierte Fehlermuster für die RLT-Anlage AUD11 im MSA.

aud11: Gleichzeitiges Heizen und adiabates Kühlen



aud11: ADK aktiv und  $T_{AUL} < T_{ABL, nWRG}$




Abbildung 120: Observierte Fehlermuster für die RLT-Anlage AUD11 im MSA.

**A22. Anzahl der Datensätze je Fehlertyp für die RLT-Anlagen im ISC-Gebäude**




Abbildung 121: Anzahl der Datensätze je Fehlertyp im Betrieb der RLT-Anlagen im ISC-Gebäude für den gesamten Betrachtungszeitraum.




Abbildung 122: Anzahl der Datensätze je Fehlertyp im Betrieb der RLT-Anlagen im ISC-Gebäude für den Trainingszeitraum.






Abbildung 123: Anzahl der Datensätze je Fehlertyp im Betrieb der RLT-Anlagen im ISC-Gebäude für den Testzeitraum.

### A23. Observierte Fehlermuster für die RLT-Anlagen im ISC-Gebäude

#### CTA01

ta01: Automatikbetrieb abgeschaltet (Wartung der Anlage)

cta01: Falsche Position der Außenluftklappen



cta01: Luftvolumenstrom und Anlage ausgeschaltet

cta01: Asynchroner Betrieb der Ventilatoren






Abbildung 124: Observierte Fehlermuster für die RLT-Anlage CTA01 im ISC-Gebäude.

### CTA02

a02: WRG Betrieb nicht im Einklang mit den Temperatur; cta02: HR-Ventil geöffnet und HR-Pumpe aus



cta02: Asynchroner Betrieb der Ventilatoren

cta02: Luftvolumenstrom über nominalem Wert

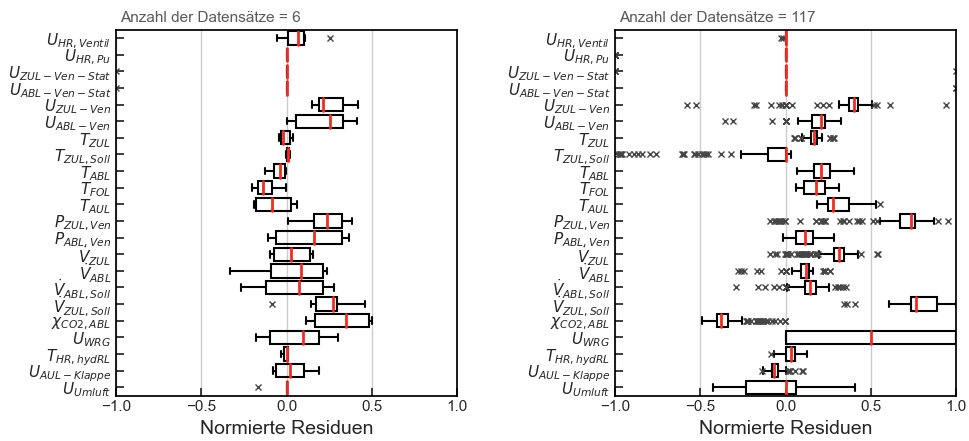


Abbildung 125: Observierte Fehlermuster für die RLT-Anlage CTA02 im ISC-Gebäude.

### CTA03

cta03: Asynchroner Betrieb der Ventilatoren






Abbildung 126: Observierte Fehlermuster für die RLT-Anlage CTA03 im ISC-Gebäude.

CTA08



ta08: Automatikbetrieb abgeschaltet (Wartung der Anlage)

cta08: Heizbetrieb mit aktiviertem WRG-Bypass



cta08: HR-Ventil geöffnet und HR-Pumpe aus

cta08: Sollwert für die Ablufttemperatur wird nicht erreicht



cta08: Asynchroner Betrieb der Ventilatoren






Abbildung 127: Observierte Fehlermuster für die RLT-Anlage CTA08 im ISC-Gebäude.



CTA17



cta17: Heizleistung bei geschlossenem HR-Ventil

17: □WRG Betrieb nicht im Einklang mit den Temperatur



cta17: Frequentiertes Ein- und Ausschalten

cta17: Umluftbetrieb ohne Heizen oder Kühlen



ta17: Automatikbetrieb abgeschaltet (Wartung der Anlage)

cta17: Keine Heizleistung bei geöffnetem HR-Ventil





Abbildung 128: Observierte Fehlermuster für die RLT-Anlage CTA17 im ISC-Gebäude.

cta17: Asynchroner Betrieb der Ventilatoren




Abbildung 129: Observierte Fehlermuster für die RLt-Anlage CTA17 im ISC-Gebäude.

#### A24. Konfusions-Matrix der Fehlerisolierung für die RLt-Anlage AUD8 im MSA-Gebäude




Abbildung 130: Konfusions-Matrix der Fehlerisolierung für die RLt-Anlage AUD8 im MSA-Gebäude. Die Isolation erfolgt für die Fehlertypen „Umluftbetrieb ohne Heizen oder Kühlen“ (Typ 1) und „Heizbetrieb ohne Wärmerückgewinnung“ (Typ 2).