

# mAIntenance

Untersuchung von KI gestütztem Instandhaltungs- und  
Energiemanagement

J. Catal, F. Giordano, J. Kurzidim, T. Lachmayer, A. Nujic,  
M. Schöny, M. Šipetić

Berichte aus Energie- und Umweltforschung

**12/2024**

Liste sowie Downloadmöglichkeit aller Berichte dieser Reihe unter  
<http://www.nachhaltigwirtschaften.at>

### **Impressum**

Medieninhaber, Verleger und Herausgeber:

Bundesministerium für Klimaschutz, Umwelt, Energie, Mobilität, Innovation und Technologie (BMK)  
Radetzkystraße 2, 1030 Wien

Verantwortung und Koordination:

Abteilung für Energie- und Umwelttechnologien

Leitung: DI (FH) Volker Schaffler, MA

Auszugsweise Abdruck ist nur mit Quellenangabe gestattet. Es wird darauf verwiesen, dass alle Angaben in dieser Publikation trotz sorgfältiger Bearbeitung ohne Gewähr erfolgen und eine Haftung der Republik Österreich und der Autorin/des Autors ausgeschlossen ist. Nutzungsbestimmungen:  
<https://nachhaltigwirtschaften.at/de/impressum/>

# **mAIntenance**

Untersuchung von KI gestütztem Instandhaltungs- und  
Energiemanagement

DI Jerik CATAL, MSc. Fabrizia GIORDANO, Dr. Jan KURZIDIM,  
DI Michael SCHÖNY, MSc. Miloš ŠIPETIĆ  
AIT Austrian Institute of Technology GmbH

Thomas LACHMAYER, DI Anna Maria NUJIC  
PKE Facility Management GmbH

Wien, Dezember, 2024

Ein Projektbericht im Rahmen des Programms



des Bundesministeriums für Klimaschutz, Umwelt,  
Energie, Mobilität, Innovation und Technologie

# Vorwort

Der vorliegende Bericht dokumentiert die Ergebnisse eines Projekts aus dem Forschungs- und Technologieprogramm Stadt der Zukunft des Bundesministeriums für Klimaschutz, Umwelt, Energie, Mobilität, Innovation und Technologie (BMK). Dieses hat die Intention Konzepte, Technologien und Lösungen für zukünftige Städte und Stadtquartiere zu entwickeln und bei der Umsetzung zu unterstützen. Damit soll eine Entwicklung in Richtung energieeffiziente und klimaverträgliche Stadt unterstützt werden, die auch dazu beiträgt, die Lebensqualität und die wirtschaftliche Standortattraktivität zu erhöhen. Eine integrierte Planung wie auch die Berücksichtigung aller betroffenen Bereiche wie Energieerzeugung und -verteilung, gebaute Infrastruktur, Mobilität und Kommunikation sind dabei Voraussetzung.

Um die Wirkung des Programms zu erhöhen, sind die Sichtbarkeit und leichte Verfügbarkeit der Projektergebnisse ein wichtiges Anliegen. Daher werden nach dem Open Access Prinzip möglichst alle Projektergebnisse des Programms in der Schriftenreihe des BMK barrierefrei publiziert und elektronisch über die Plattform [www.NachhaltigWirtschaften.at](http://www.NachhaltigWirtschaften.at) frei zugänglich gemacht. In diesem Sinne wünschen wir allen Interessierten und Anwender:innen eine interessante Lektüre.

DI Theodor Zillner

Leiter der Abt. Energie- und Umwelttechnologien

Bundesministerium für Klimaschutz, Umwelt, Energie, Mobilität, Innovation und Technologie (BMK)

## Inhaltsverzeichnis

<b>1</b>	<b>Kurzfassung</b>	<b>7</b>
<b>2</b>	<b>Abstract</b>	<b>8</b>
<b>3</b>	<b>Ausgangslage</b>	<b>9</b>
3.1.	Ausgangssituation	9
3.1.1.	Motivation für das Projekt	9
3.1.2.	Forschungsfrage	10
3.1.3.	Zielsetzungen	10
3.2.	Stand des Wissens	10
3.2.1.	Zeitreihenvorhersage	10
3.2.2.	Optimale Steuerung	12
3.2.3.	Fehler- und Anomalieerkennung	13
3.2.4.	BRICK-Datenmodell	17
<b>4</b>	<b>Projekthalt</b>	<b>19</b>
4.1.	Use Case Anforderungsanalyse	19
4.1.1.	Beschreibung der Use Cases	19
4.1.2.	Methodische Vorgehensweise der Anforderungsanalyse	19
4.2.	Datenerhebung	21
4.2.1.	Demonstrationsgebäude	21
4.2.2.	Anlagenmonitoring	21
4.2.3.	IoT Netzwerk	22
4.2.4.	Störbehebungen IoT Netzwerk	24
4.3.	Semantisches Datenmodell	25
4.4.	Konzept Softwareframework	26
4.5.	Modellentwicklung	27
4.5.1.	Machine Learning Modelle - Use Case 1	27
4.5.2.	Machine Learning Modelle - Use Case 2	29
4.5.3.	Machine Learning Modelle - Use Case 3	30
<b>5</b>	<b>Ergebnisse</b>	<b>33</b>
5.1.	Modellvalidierung	33
5.1.1.	Ergebnisse der Validierung – Use Case 1	33
5.1.2.	Ergebnisse der Validierung – Use Case 2	34
5.1.3.	Ergebnisse der Validierung – Use Case 3	36
5.2.	Evaluierung	38
5.2.1.	Ergebnisse der Evaluierung – Use Case 2	38
5.2.2.	Ergebnisse der Evaluierung – Use Case 3	44
5.2.3.	Zusammenfassung Ergebnisse Canvas Methode	49

5.2.4.	Zusammenfassung Ergebnisse Wirtschaftlichkeit .....	49
5.2.5.	Erkenntnisse Wirtschaftlichkeitsbetrachtung .....	50
<b>6</b>	<b>Schlussfolgerungen .....</b>	<b>52</b>
6.1.	Gewonnene Erkenntnisse Use Case 1 .....	52
6.2.	Erkenntnisse Use Case 2 .....	52
6.3.	Erkenntnisse Use Case 3 .....	52
6.4.	Verwertung der Ergebnisse für relevante Zielgruppen .....	53
6.5.	Rechtliche Hürden.....	53
6.6.	Verbreitungsaktivitäten und Marktpotential.....	54
<b>7</b>	<b>Ausblick und Empfehlungen .....</b>	<b>55</b>
7.1.	Empfehlungen für weiterführende Forschungs- und Entwicklungsarbeiten.....	55
7.2.	Potenzial für Demonstrationsvorhaben (Chancen / Herausforderungen / Risiken bei der Realisierung / Umsetzung in Richtung Demonstrationsprojekt) .....	55
<b>8</b>	<b>Verzeichnisse .....</b>	<b>56</b>
8.1.	Abbildungsverzeichnis .....	56
8.2.	Tabellenverzeichnis.....	56
8.3.	Literaturverzeichnis .....	57
<b>9</b>	<b>Anhang.....</b>	<b>61</b>
9.1.	Data Management Plan (DMP) .....	61
9.2.	Use Case Beschreibungen .....	65
9.2.1.	Use Case 1 Anforderungen .....	65
9.2.2.	Use Case 2 Anforderungen .....	68
9.2.3.	Use Case 3 Anforderungen .....	70

# 1 Kurzfassung

Der Gebäudesektor spielt eine bedeutende Rolle zur Erreichung der Pariser Klimaziele, da er für fast ein Drittel der weltweiten ausgestoßenen CO<sub>2</sub> Emissionen verantwortlich ist. Fortschrittliche prädiktive Steuerungsansätze haben in den letzten Jahren hohe Aufmerksamkeit im Bereich der Forschung erlangt und erweisen sich als vielversprechende Lösung um die Gebäudeeffizienz zu steigern. So können datengesteuerte Lastvorhersagemodelle für individuelle Gebäudeenergiesysteme mit der Zunahme von kostengünstig installierter IoT-Sensorik leicht zugängliche Monitoringdaten nutzen.

Das kooperative F&E-Projekt mAMaintenance untersuchte, in welcher Form der Einsatz künstlicher Intelligenz gebäudetechnische Versorgungssysteme effizienter und zuverlässiger gestalten kann. So wurde angestrebt, im Gebäude gesammelte Sensordaten mittels Machine Learning auszuwerten und durch die neue Datenlage die daraus abgeleiteten Erkenntnisse dem FM über ein Dashboard zur Verfügung zu stellen. Hierfür wurden Anwendungsfälle (Use Cases) im Aufgabenbereich des Energie- und Instandhaltungsmanagement definiert.

Zum Zwecke der Datenerfassung, Anlagenüberwachung, Modellvalidierung sowie funktionellen Evaluierung der Anwendungsfälle wurde die FUTUREbase als Testumgebung ausgewählt. Hierbei handelt es sich um ein vierstöckiges Forschungs- und Bürogebäude am Standort Wien. Zusätzlich zu den bestehenden Anlagenmonitoring wurde ein IoT-Sensornetzwerk aufgebaut, um relevante Informationen betreffend Büroraumklima zu sammeln. Die Abbildung eines auf BRICK basierenden Datenmodells der Gebäudetopologie, versorgungstechnischen Systeme sowie deren Datenpunkte ermöglichte es semantisches Wissen maschinenlesbar aufzubereiten.

Durch Kombinationen der gesammelten Datensätze und dem semantischen Datenmodell wurden darauf erste Vorhersagen betreffend des Gebäudeenergieverbrauchs, thermischen Raumkomforts und Fehlererkennung innerhalb der Gebäudeautomation durchgeführt. Die generierten datenbasierten Machine Learning Modelle wurden hierfür mit den über mehrere Jahre aufgezeichneten und aufbereiteten Daten zunächst trainiert und anschließend validiert. Des Weiteren wurden funktionelle Evaluierungen hinsichtlich der Vorhersage für die thermische Behaglichkeit in Büros einer HLK-Zone und der detektierten Anomalien überprüft.

Hinsichtlich der Vorhersage des Gebäudeenergieverbrauchs zeigten sich gute Ergebnisse durch die Verfügbarkeit langer Datenzeitreihen mit hoher Qualität. Die Prognosen des thermischen Komforts in den Büros erwiesen sich als ungenauer. Bei der Evaluierung mit Messreihen für thermische Behaglichkeitsbetrachtungen ergaben sich jedoch hinreichend genaue Übereinstimmungen um Komfortverletzungen in Büroräumen für einen Zeitraum von bis zu 3 Tagen für das Facility Management abzuschätzen. Betreffend der Fehlerdetektion wurde mit Hilfe von Autoencodern verschiedene Fehlerklassifizierungen durch die Analyse der aufgezeigten Anomalien vorgenommen. Der Ansatz, das Brick-Datenmodell zur Auswahl von Datenpunkten zur Spezifikation einzelner Autoencoder zu nutzen, erwies sich als leistungsstark.

Eine Wirtschaftlichkeitsanalyse zeigte eine Amortisationszeit von etwa 2,7 Jahren für das KI-Tool, was langfristig zu einer Steigerung der Energieeffizienz führt. Die Anwendung von künstlicher Intelligenz im Gebäudemanagement bietet ein großes Marktpotenzial, insbesondere für Facility Manager und Industriebetriebe, die von der Optimierung des Energieverbrauchs und der Anomalieerkennung profitieren können.

## 2 Abstract

The building sector plays a significant role in achieving the Paris climate goals, as it is responsible for almost a third of global CO<sub>2</sub> emissions. Advanced predictive control approaches have attracted a great deal of attention in the field of research in recent years and are proving to be a promising solution for increasing building efficiency. For example, data-driven load prediction models for individual building energy systems can utilize easily accessible monitoring data with the increase of low-cost installed IoT sensor technology.

The cooperative R&D project mAMaintenance investigated how the use of artificial intelligence can make technical building supply systems more efficient and reliable. The aim was to evaluate sensor data collected in the building using machine learning and make the findings derived from the new data available to the FM via a dashboard. To this end, use cases were defined in the area of energy and maintenance management.

FUTUREbase was selected as the test environment for data acquisition, system monitoring, model validation and functional evaluation of the use cases. This is a four-storey research and office building at the Vienna site. In addition to the existing system monitoring, an IoT sensor network was set up to collect relevant information regarding the office climate. The mapping of a BRICK-based data model of the building topology, supply systems and their data points made it possible to process semantic knowledge in a machine-readable way.

By combining the collected data sets and the semantic data model, initial predictions were made regarding building energy consumption, thermal room comfort and fault detection within the building automation system. The generated data-based machine learning models were first trained with the data recorded and processed over several years and then validated. Furthermore, functional evaluations were carried out with regard to the prediction of thermal comfort in offices in an HVAC zone and the detected anomalies.

With regard to the prediction of building energy consumption, good results were achieved due to the availability of long, high-quality data time series. The predictions of thermal comfort in the offices proved to be less accurate. However, the evaluation with measurement series for thermal comfort considerations resulted in sufficiently accurate matches to estimate comfort violations in offices for a period of up to 3 days for facility management. With regard to fault detection, various fault classifications were carried out with the help of autoencoders by analyzing the anomalies identified. The approach of using the brick data model to select data points for the specification of individual autoencoders proved to be powerful.

A profitability analysis showed a payback period of around 2.7 years for the AI tool, leading to an increase in energy efficiency in the long term. The application of artificial intelligence in building management offers great market potential, especially for facility managers and industrial companies that can benefit from the optimization of energy consumption and anomaly detection.

# 3 Ausgangslage

## 3.1. Ausgangssituation

### 3.1.1. Motivation für das Projekt

Der Gebäudesektor spielt zur Erreichung der Pariser Klimaziele eine bedeutende Rolle, da er für 30 % des weltweiten Energieverbrauchs und 27 % der weltweiten betrieblichen CO<sub>2</sub>-Emissionen verantwortlich ist. (Hamilton et al. 2022) Fortschrittliche prädiktive Steuerungsansätze, haben in den letzten Jahren hohe Aufmerksamkeit in der Forschung erlangt und erweisen sich als vielversprechende Lösung. So können datengesteuerte Lastvorhersagemodelle für individuelle Gebäudeenergiesysteme mit der Zunahme von kostengünstig installierter IoT-Sensorik leicht zugängliche Monitoringdaten nutzen (Wang et al. 2019) um eine optimierte Verwaltung des Gebäudebetriebs zu ermöglichen. Der Objektbetreuer bzw. Betriebstechniker kann so durch datenbasierte Handlungsempfehlungen unterstützt werden.

Eine interne Analyse betreffend bisherige Aktivitäten zur Implementierung von digitalen Werkzeugen innerhalb des technischen Gebäudemanagements listet Hemmnisse betreffend deren Einsatz auf:

- Grundsätzlich ist das Kosten-Nutzen-Verhältnis für eine automatisierte Fehlererkennungs- und -diagnose in Gebäuden und bei Heizungs-, Lüftungs-, Klima- und Kälte-Systemen (HLKK) relativ hoch, was teilweise auf den Mangel an fehlender Sensorik in den GAS sowie einem Defizit an Daten zur Quantifizierung des Nutzens zurückzuführen ist.
- Das Gebäude- und Anlagenverhalten ist ebenso schwierig vorherzusagen. Da die meisten HLKK-Entwürfe einzigartig sind, ist eine genaue Abbildung durch abstrahierte mathematische Modelle aus finanziellen Überlegungen zu zeit- und arbeitsaufwändig.
- Zudem können Testsignale während des normalen Betriebs aufgrund möglicher Beschwerden der Benutzer, inakzeptabler Energieeinbußen oder möglicher Geräteschäden - nicht injiziert werden.
- Zur Erfüllung der vielfältigen Aufgabenstellungen bedient sich das technische Gebäudemanagement unterschiedlichster Informationssysteme. Hierzu zählen klassisch das Computer Aided Facility Management (CAFM) sowie objektspezifische Gebäudeautomationsystem (GAS). Große Datenmengen jeweiliger Feldsensoren können jedoch von einem derzeitigen CAFM, welches in erster Linie zur Erfüllung der vertraglichen Vereinbarungen zwischen Kunde und Dienstleister eingesetzt werden soll, nicht als praxiserprobtes Analyse- und Diagnosewerkzeug verarbeitet werden.
- Des Weiteren werden hoch spezialisierte Problemlösungskompetenzen zur digitalen Datenerfassung, -weiterverarbeitung und -analyse benötigt, welchem ein monetär überhöhter Schulungsaufwand des Personals entgegensteht.

Die Einbindung von KI-gestützter Lastvorhersagen und Fehlererkennung soll dem Betreiber dazu verhelfen, eine optimierte Betriebsweise seiner Anlagen zu erhalten. Das Vorhaben beabsichtigte demnach, durch den Einsatz von prädiktiven und selbstlernenden Algorithmen sowohl Energie- als auch Instandhaltungskosten eines HLKK-Systems zu reduzieren und dabei gleichzeitig eine effizientere und zuverlässigere Betriebsweise zu erzielen

### 3.1.2. Forschungsfrage

Die angedachte Projektidee beschäftigt sich mit der Forschungsfrage inwieweit künstliche Intelligenz (Machine Learning-Methoden) das operative Facility Management (Instandhaltung und Energiemanagement) unterstützen kann um eine Performanzsteigerung hinsichtlich optimierter Betriebsweisen, Nutzerkomforts bzw. Fehlererkennung innerhalb des HLKK-Systems zu erzielen.

### 3.1.3. Zielsetzungen

Ausgehend von zuvor beschriebener Ausgangslage und der Forschungsfrage wurden nachfolgende qualitative und quantitative Projektziele definiert. Wiewohl aufgrund des Projektverlaufs der konzeptionelle Entwurf des KI-Tools prioritär verfolgt wurde.

Qualitative und quantitative Projektziele:

**Ziel 1:** optimierter Betrieb der Heiz- und Kälteversorgung hinsichtlich Energiemanagement, durch prädiktiven Ansatz

**Ziel 2:** zuverlässiger Betrieb der HLKK-Anlagentechnik, durch datenbasierte, selbstlernende Fehlererkennung

**Ziel 3:** Konzeptioneller Entwurf und prototypische Implementierung eines KI-Tools zur automatisierten Fehlererkennung sowie energetischen Anlagenoptimierung mittels KI-basierter Datenanalyse und Empfehlung

**Ziel 4:** angestrebte messbare Energieeinsparung (10 bis 15 %) gegenüber aktuellem Betrieb

**Ziel 5:** angestrebter messbarer Komfortgewinn (PPD < 20 % im Heizfall, PPD < 25 % im Kühlfall) in umstrittenen Raum- bzw. Gebäudezonen

## 3.2. Stand des Wissens

Dieses Kapitel stellt einen kurzen Überblick über die für das Projekt relevante Fachliteratur dar. Hierbei wird auf die Themenbereiche Zeitreihenprognose, optimale Steuerung, Fehler- und Anomalieerkennung sowie Datenmodelle eingegangen. Für jeden Themenbereich konnten sowohl klassische Methoden als auch neuartige Ansätze basierend auf Deep Learning identifiziert werden. Letztere verfügen bei ausreichender Datenlage im Kontext zur Ausgangslage über ein hohes Anwendungspotential.

### 3.2.1. Zeitreihenvorhersage

Im Allgemeinen ist die Zeitreihenvorhersage ein Sonderfall der Sequenz-zu-Sequenz-Transformation. Sie kann auch als Regressionsproblem formuliert werden:

$$y = f(u, x)$$

wobei  $y$  die vorhergesagten Werte (Zonentemperaturen, Stromverbrauch usw.),  $u$  die Kontrollvariablen und  $x$  die externen Variablen (keine Kontrolle) sind.

Die  $f$ -Funktion wird als neuronales Netzwerk mit einer großen Anzahl von Gewichten aufgebaut. Diese Gewichte werden optimiert, um eine minimale Verlustfunktion zu erhalten. Die Verlustfunktion wird aus der Abweichung zwischen dem vorhergesagten Wert und den gemessenen Werten aufgebaut. Eine gängige Verlustfunktion für die Regression ist beispielsweise der kleinste-Quadrat-Verlust:

$$L_{square} = \sum_i (y_i - y'_i)^2$$

Wobei  $y'_i$  die tatsächlich gemessenen Werte sind und die Summe über alle Instanzen geht. Die Optimierung der Gewichte des neuronalen Netzwerks erfolgt normalerweise mit stochastischen Gradientenabstiegsmethoden. Die Deep-Learning-Frameworks propagieren die Fehlerableitungen zurück zu den Schichtgewichten und aktualisieren alle Gewichte in jeder Iteration gemäß der Gradientenabstiegsmethode (Goodfellow et al., 2016a).

Eine gute Übersicht über Methoden der Zeitreihenvorhersage für den Energieverbrauch von Gebäuden wurde von Deb et al. veröffentlicht (Deb et al., 2017a). Klassische Methoden auf Basis maschinellen Lernens unter Verwendung aufgezeichneter Zeitreihen werden häufig zur Vorhersage des Energieverbrauchs eingesetzt, darunter künstliche neuronale Netze, autoregressive Modelle wie ARIMA (Autoregressive Integrated Moving Average), Support Vector Machine Regression, Fuzzy-Modelle, k-Nearest-Neighbors-Regression, Regressionsbäume (Russel & Norvig, n.d.) und ihre Hybridkombinationen. Rekurrente neuronale Netze werden auch häufig zur Sequenz- oder Zeitreihenvorhersage verwendet (Goodfellow et al., 2016b), wie beispielsweise Long-Short Term Memory-Netze oder Gated Recurrent Units.

Zu den klassischen Methoden gehören autoregressive integrierte gleitende Durchschnittsmodelle (ARIMA) und ähnliche Modelle, die „Autoregression“ und „gleitenden Durchschnitt“ verwenden (De Gooijer & Hyndman, 2006). In einem ARIMA-Modell wird der nächste Wert einer Zeitreihe grundsätzlich als gewichtete Summe vergangener Werte und vergangener Fehler modelliert (Ho et al., 2002). Hyperparameter des ARIMA-Modells sind die Anzahl der verzögerten Beobachtungen, die in der Autoregression verwendet werden, die Anzahl der Rohbeobachtungen und Differenzen (Integration) und die Größe des gleitenden Durchschnittsfensters. ARIMAX bezieht sich auf ein ähnliches Modell, in dem auch exogene (X) Variablen berücksichtigt werden.

Für Vorhersage- und Transformationsaufgaben bei sequenziellen Daten werden häufig rekurrierende neuronale Netzwerke verwendet. Die Grundidee ist, dass für jeden Zeitschritt  $t$  ein interner Zustandsvektor ( $h^t$ ) definiert und von einem neuronalen Netzwerk aktualisiert wird:

$$h^t = f(h^{t-1}, x^t, \theta)$$

Das externe Signal ( $x^t$ ) – man kann es sich als gemessene Eingangsdaten vorstellen – und der trainierbare Parametervektor  $\theta$  des Modells bestimmen, wie der interne Zustand aktualisiert wird. Das Training solcher einfachen rekurrenten neuronalen Netzwerke wird durch numerische Probleme wie verschwindende oder explodierende Gradienten durch Backpropagation im Laufe der Zeit erschwert und berücksichtigt oft keine langfristigen Abhängigkeiten (Goodfellow et al., 2016c). Um diese Probleme zu überwinden, wurde 1997 von Hochreiter und Schmidhuber das Long Short Term Memory (LSTM) vorgeschlagen (Hochreiter & Schmidhuber, 1997). Es enthält eine sogenannte LSTM-Zelle, die wie eine Speichereinheit fungiert, die nur aktualisiert wird, wenn das Forget Gate ausgelöst wird. Die Parameter des Forget Gate werden zusammen mit den anderen Parametern anhand der Daten trainiert. Ein ähnliches Konzept findet sich bei Gated Recurrent Units mit „Update“ und „Reset“ Gates.

Convolutional Neural Networks, die im Allgemeinen auf Daten mit bekannter gitterartiger Struktur angewendet werden, können auch für diese Regressionsvorhersageaufgaben zur Zeitreihenvorhersage verwendet werden (Goodfellow et al., 2016d). Lara Benitez et al. (Lara-Benítez et al., 2020) haben Temporal Convolutional Neural Networks (TCN) zur Vorhersage des Strombedarfs von Ladestationen für Elektrofahrzeuge verwendet. Sie erzielten mit TCN eine höhere Genauigkeit als mit LSTM.

Neuronale Netzwerke mit Aufmerksamkeitsmechanismen lernen, sich auf relevante Dimensionen der Eingabe und/oder verborgene Vektoren zu konzentrieren. Im Kontext der Übersetzung kann Aufmerksamkeit beispielsweise einem neuronalen Netzwerk ermöglichen, zu lernen, Wörter in Satzpaaren aus verschiedenen Sprachen anzuordnen. Während frühere Arbeiten Aufmerksamkeit mit rekurrierenden neuronalen Netzwerken kombinierten, haben rein aufmerksamkeitsbasierte Netzwerke seit 2017 bedeutende Durchbrüche in der Verarbeitung natürlicher Sprache erzielt (Vaswani et al., 2017). In letzter Zeit wurden Aufmerksamkeitsnetzwerke auch für die Aufgabe der Prognose langer Zeitreihensequenzen vorgeschlagen (Zhou et al., 2021a). Im Aufmerksamkeitsnetzwerk wird das neuronale Netzwerk darauf trainiert, wichtige Punkte in der Sequenz zu erkennen, die für die Vorhersage relevant sind. Aufmerksamkeitsnetzwerke und Transformer-Architekturen wurden erstmals für Probleme der Verarbeitung natürlicher Sprache (Textsequenzen) verwendet.

2018 haben Forscher von Amazon das Deep State Space Model (Rangapuram et al., 2018) für die Zeitreihenprognose vorgeschlagen. Es verbindet die klassischen Zustandsraummodelle mit latenten Variablen mit Deep Learning, das komplexe Muster verarbeiten kann. Das Modell wurde anhand öffentlich verfügbarer Datensätze zu Tourismus, Verkehr und Stromverbrauch überprüft und eine Leistung auf dem neuesten Stand der Technik erzielt.

### **3.2.2. Optimale Steuerung**

Nach der Vorhersageaufgabe beinhalten UC1 und UC2 die Abgabe von Empfehlungen zum Betrieb des HLK-Systems. Die Ermittlung dieser Empfehlungen kann als Instanz eines optimalen Steuerungsproblems angesehen werden. Dies beinhaltet die Definition einer Zielfunktion (Verlustfunktion) basierend auf unseren Zielmaßen (Energieverbrauch, Temperaturkomfort, gepumpte Grundwassermenge, Zustandsänderungshäufigkeit und andere einschränkende Bedingungen).

Um ein mathematisches Optimierungsmodell (Model Predictive Control (Grüne & Pannek, 2017a)) zu erstellen, sollte aus diesen Werten eine Verlustfunktion konstruiert werden, und die optimalen Steuerungsparameter werden durch Optimierung dieser Verlustfunktion in Bezug auf die Steuerungsparameter erhalten.

Eine Übersicht über klassische vs. modellprädiktive Steuerungsmethoden in Gebäudeenergieanwendungen finden sich in der Übersicht von (Afram & Janabi-Sharifi, 2014). Die in HLK-Anwendungen von MPC-Reglern verwendeten gängigen Leistungskennzahlen umfassen Energie- und Kosteneinsparungen, Spitzenlastverschiebung, Reduzierung von Schwankungen, Robustheit gegenüber Störungen usw. Es zeigt sich, dass das MPC für HLK-Systeme die meisten Steuerungstechniken mit den oben genannten Leistungskennzahlen übertrifft.

In einer österreichischen Studie verwendeten Schirrer et al. (Schirrer et al., 2016) einen Model Predictive Control (MPC)-Algorithmus, um optimale Solltemperaturen für Betonkerne (die als TABS – thermisch aktivierte Bausysteme – bezeichnet wurden) zu berechnen, wobei die MPC ein physikalisches Simulationsmodell (Dymola-Modell) verwendete. In diesem Projekt erstellte man ein

datengesteuertes Modell, bei dem die Vorhersagen ausschließlich auf gemessenen Daten basieren, ohne dass eine detaillierte physikalische Simulation erstellt werden muss. Dieser Ansatz steht im Einklang mit der Methode von Mtibaa et al. (Mtibaa et al., 2021b), die das physikalische Simulationsmodell durch ein daten- und maschinenlerngesteuertes Vorhersagemodell ersetzen. Das auf LSTM (siehe oben) basierende Vorhersagemodell wurde ausschließlich anhand historischer Daten trainiert.

Die modellprädiktive Regelung kann als wesentlicher Bestandteil des Energiemanagements auf der Nachfrageseite (DSM) dienen. Eine aktuelle Übersicht über datengesteuerte prädiktive Regelung im Zusammenhang mit energieflexiblen Gebäuden (Kathirgamanathan et al., 2021) fasst mehr als hundert Artikel zusammen, die sich mit modellbasierter prädiktiver Regelung für Gebäudeenergie- und HLK-Systeme befassen. White-Box-Modelle nutzen Simulationen aus der Physik, die viel rechnen, was viel Energie braucht. Deshalb werden datenbasierte Black-Box-Modelle immer beliebter. Grey-Box-Modelle mischen diese beiden Arten, indem sie physikalische Modelle mit an die Daten angepassten Parametern kombinieren. Kathirgamanathan weist jedoch auf Probleme hin: Die Ergebnisse sind oft nicht gut für andere Gebäude anwendbar, und Regler werden selten in echten Gebäuden getestet. Außerdem gibt es nicht genug Benchmark-Datensätze, was es schwer macht, Modelle zu vergleichen.

Aufgaben der optimalen Steuerung können mit Reinforcement Learning (RL) verknüpft werden. RL beschäftigt sich damit, wie ein Agent (z. B. ein intelligenter Controller), der mit einer Umgebung interagiert, Aktionen auswählt, um ein Belohnungssignal zu maximieren. Dieses Belohnungssignal steht oft im Gegensatz zur Zielfunktion bei der modellprädiktiven Steuerung, z. B. eine Kombination aus minimalem Energieverbrauch und maximalem thermischen Komfort. RL-Methoden basieren häufig auf dem Lernen und Verbessern einer Wertfunktion (Erwartete Belohnung für Zustände oder Zustände und Aktionen) und/oder einer Richtlinienfunktion (Zuordnung von Zuständen zu Aktionen). (Sutton & Barto, 2018).

### **3.2.3. Fehler- und Anomalieerkennung**

Die Anomalieerkennung (Ausreißerererkennung) ist ein Prozess zum Erkennen von Daten im Datensatz, die vom Rest des Datensatzes abweichen. Die Anomalieerkennung ist naturgemäß ein sehr unausgewogenes Problem, wobei die Anzahl anomaler Ereignisse normalerweise viel geringer ist als die Gesamtzahl der verfügbaren Messungen.

Da das Feld in den letzten Jahrzehnten aktiv war, gibt es eine Vielzahl von Methoden und Ansätzen, die in verschiedenen Bereichen entwickelt und angewendet werden. Im Projekt mAIntenance liegt der Schwerpunkt speziell auf datenbasierten Modellansätzen, die in irgendeiner Weise Deep Learning beinhalten, daher wird sich der folgende Überblick über den Stand der Technik auch nur auf diese Methoden konzentrieren.

Machine Learning Methoden werden grob in unsupervised, supervised und semi-supervised Untergruppen eingeteilt. Unsupervised Methoden lernen aus unbeschrifteten Daten, d. h. der Algorithmus verarbeitet den Datensatz selbst und erkennt Muster darin, wodurch er neues Wissen ableitet. Zu den unsupervised Methoden gehören Clustering, Assoziationsregeln und Dimensionsreduzierung.

Supervised Lernmethoden versuchen, eine Funktion zu optimieren, die die Eingabedaten den Ausgabedaten (normalerweise Ziel genannt) zuordnet. Zu diesem Zweck wird dem Algorithmus in der

Trainingsphase ein Satz von Merkmalsdaten und ein Satz von Beschriftungen bereitgestellt, für die die Zuordnungsfunktion trainiert wird. Anschließend wird eine Zuordnungsfunktion nur mit Merkmalsdaten bereitgestellt, für die eine vorhergesagte Beschriftung zurückgegeben wird. Semi-supervised Methoden verwenden (normalerweise manuelle) Beschriftungen einer kleinen Anzahl von Proben, aus denen Verallgemeinerungen vorgenommen werden können.

Darüber hinaus werden Anomalien je nach Umfang in drei Gruppen eingeteilt (Hayes & Capretz, 2015): Punktanomalien, Kontextanomalien und kollektive Anomalien. Punktanomalien: Einzelne Datenpunkte, die im Kontext des gesamten Datensatzes als abnormal gelten. Kontextanomalien: Datensegmente, die im Vergleich zu zugehörigen Metainformationen (z. B. Tageszeit) als abnormal erscheinen, auch wenn sie im allgemeinen Betriebsbereich liegen. Kollektive Anomalien: Gruppen von Datenpunkten, die zusammen im Vergleich zum Rest des Datensatzes als abweichend angesehen werden.

Insbesondere für die Deep-Learning-Ansätze wurde in (Pang et al., 2021a) eine Reihe von Herausforderungen für die allgemeine Anomalieerkennung identifiziert. Zu diesen Herausforderungen gehörten eine niedrige Anomalieerkennungsrate (aufgrund der Vielfalt und Seltenheit anomaler Datenmessungen), Anomalieerkennung in hochdimensionalen und/oder nicht unabhängigen Daten, dateneffizientes Lernen von Normalität / Abnormalität, rauschresistente Anomalieerkennung, Erkennung komplexer Anomalien und Anomalieerläuterung.

Darüber hinaus identifizieren dieselben Autoren eine Reihe von Möglichkeiten, welche die Deep Anomaly Detection bietet, von denen die Deep Weekly-überwachte Anomalieerkennung herausgegriffen werden kann. Im Projekt wird angestrebt, Vorfallbedingungen aus dem Basiszeitraum zu extrahieren, um bestimmte Datenpunkte oder Zeiträume als anomal zu kennzeichnen und die Anomalieerkennung zu verbessern. Besonders geeignet erscheint die Erkennung kollektiver Anomalien, die von mehreren Variablen abhängen oder zeitliche Komponenten beinhalten. Dieser Ansatz wurde bisher selten untersucht, ist jedoch vielversprechend für die Erkennung komplexer Anomalien. Im Gebäudebereich konzentrieren sich Anomalieerkennungen oft auf einzelne Datenpunkte (z. B. Betriebsgrenzen) und selten auf Beziehungen zwischen Datenpunkten. Ein Beispiel für eine komplexe Bedingung ist der gleichzeitige Betrieb von Heiz- und Kühlkreisläufen in einer Zone, der durch entsprechende Regeln identifiziert werden kann.

Das Modell kann an die Domäne angepasst werden, indem die Systemtopologie, integriert wird. Die Topologie wird in einem Graphen dargestellt und genutzt, um Eingabevariablen zu gewichten. Dabei beeinflussen (kontextuell oder räumlich) verwandte Datenpunkte den Anomalierang eines Punkts stärker als entfernte oder nicht verwandte Datenpunkte. Verwandte Kandidatenmethoden zur Operationalisierung sind Graph-Neural-Networks (Bloemheuvel et al., 2022) und Graph-Convolutional-Neural-Networks (Kipf & Welling, 2017). Eine weitere gängige Methode zur Darstellung von System, Topologie und anderen Metadaten sind Ontologien wie BRICK (Balaji et al., 2018a), Saref4Bldg (SAREF Extension for Building, n.d.), BOT (Rasmussen et al., 2021) und IfcOwl (Pauwels & Terkaj, 2016).

Graph-Convolutional-Neural-Networks kombinieren den Convolutional-Neural-Network-Ansatz, der üblicherweise für Bildverarbeitungs- und Bildverarbeitungsaufgaben verwendet wird, mit Graphdaten, indem sie die Graphkanten nutzen, um kontextuelle Nähe und Relevanz zwischen Datenpunkten zu kodieren.

Autoencoder bieten einen einfachen Einstiegsansatz, der sehr effektiv erscheint. In (Araya et al., 2016) schlagen die Autoren ein komplettes Framework vor, das eine auf Autoencoder basierende Musterlern-Engine umfasst, deren Vorhersagen sie dann mit beobachteten Messungen des Systems vergleichen. Das System wird mithilfe zurückgehaltener Anomaliedatensätze und auch künstlicher Anomaliedatensätze gründlich getestet und erreicht mit einer geringen Anzahl von Merkmalen eine Falsch-Positiv-Rate von 12,7.

Eine Übersicht der automatischen Fehlererkennung und -diagnose für Gebäudesysteme findet sich in (Shi & O'Brien, 2019).

Tabelle 1 fasst die wichtigsten Kategorien von Methoden zusammen, die für die drei Aufgaben ermittelt wurden.

Tabelle 1: Zusammenfassung der identifizierten Methoden

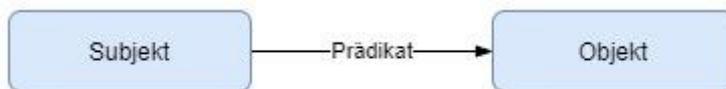
Aufgabe	Kategorien von Methoden/Modellen	Vor- und Nachteile
Zeitreihenprognose	<b>1D-ConvNets:</b> Eindimensionale Faltungsnetzwerke mit einem Kanal pro physikalischer Variable	Relativ einfache neuronale Netzwerkarchitektur, potenziell sehr genau mit ausreichend Trainingsdaten.
	<b>LSTM:</b> long short-term memory recurrent neural network (Langes Kurzzeitgedächtnis, wiederkehrendes neuronales Netzwerk).	Klassisches wiederkehrendes Netzwerk, möglicherweise sehr genau mit ausreichend Trainingsdaten.
	Aufmerksamkeitsbasierte neuronale Netzwerke, z.B. (Zhou et al., 2021b).	Potentiell effizient und genau, neuartig, aber komplexe Architektur.
	Regressionsbäume/Regressionswälder/Gradientenbaumboosting.	Möglicherweise sehr genau und schnell zu trainieren. Keine Möglichkeit zum netzwerkbasieren Transferlernen.
	Support vector machine (SVM) regression	Möglicherweise genauer bei kleineren Datenmengen. In den neuesten Arbeiten weniger verwendet. Keine Möglichkeit zum netzwerkbasieren Transferlernen.
	Mehrschichtiges Perzeptron: Neuronales Netzwerk nur mit vollständig verbundenen Schichten.	Wahrscheinlich ineffizient, wenn der Vorhersagehorizont und die berücksichtigte Historie mehr als eine Zeitstufen umfassen. Kann als Grundlage für den Vergleich anderer Architekturen betrachtet werden.
	Lineare Regression basierend auf vorherigen Zeitschritten	Grundlage (im einfachsten Fall) berücksichtigt nicht die Zeitstruktur der Daten.
Optimale Steuerung	ARIMAX: Autoregressive Integrated Moving Average with Exogenous Variables (Autoregressiver integrierter gleitender Durchschnitt mit exogenen Variablen)	Grundlage: Klassische Zeitreihenvorhersagemethode, die als Grundlage für die Messung der Leistung neuerer Modelle verwendet werden kann.
	Optimierungsbasierte Zeitreihenprognose mit nichtlinearem Programmierungslösern	Komplexes Modell, das für einen Standard-Löser zu "unscharf" sein kann. Optimale Lösung für ein Blackbox-Modell ist möglicherweise nicht optimal für das reale System.
	Optimierungsbasierte Zeitreihenprognose mit Metaheuristischer Optimierungstechnik (z.B. genetischer Algorithmus).	Rechenintensiv. Optimale Lösung für ein Blackbox-Modell ist möglicherweise nicht optimal für das reale System.
	Reinforcement learning (Verstärktes Lernen), trainiert gegen "Blackbox-Umgebung"	Die in der Blackbox-Umgebung trainierte Politik kann im realen System schlecht ausführen. Potenziell lange Trainingszeit. Nach dem Training ist die Inferenz jedoch sehr schnell.

	Reinforcement learning (Verstärktes Lernen) vortrainiert in einem hochgenauen Simulationsmodell	Erfordert ein Simulationsmodell. Potenziell lange Trainingszeit. Nach dem Training ist die Inferenz jedoch sehr schnell.
	Regelbasierte Steuerung (Wie-Ist-Zustand)	Grundlage (Status quo)
<b>Fehler- und Anomalie-Erkennung</b>	Autoencoders	Relativ einfach zu implementieren. Hohe Wahrscheinlichkeit der Überanpassung bei hochdimensionalen Daten. Potenziell nützlich bei manuell ausgewähltem Datensatz zum Training.
	GCN: Graph convolutional neural networks (Grafische Faltungsn€nale Netze)	Verflechtung und gegenseitige Interaktion von Datensätzen können leichter mit GCN kodiert werden.
	LSTM: Long short-term memory (Langes Kurzzeitgedächtnis)	Vorhersagebasierter Ansatz. Wahrscheinlich zu langsam und zu anfällig für Überanpassung bei einer größeren Anzahl von Zeitreihen. Kann mit einer kleinen Anzahl manuell ausgewählter Zeitreihen oder kontextbezogener Auswahl funktionieren.
	LSTM encoder-decoder	Gute Methode, um den Autoencoder-Ansatz mit der zeitlichen Komponente zu kombinieren.

### 3.2.4. BRICK-Datenmodell

In den letzten Jahren sind mehrere Datenmodell-Schemata wie Project Haystack und SAREF (Daniele 2015) entstanden, welche die Verwendung von Metadaten adressieren und damit die Eigenschaften verschiedener in Gebäude verwendeter Geräte, Sensoren und Steuerungen erfassen. Das BRICK-Schemata baut auf diese Bemühungen auf und kann hierbei als maschineninterpretierbares Datenmodell unterstützen. BRICK folgt dem Resource Description Framework (RDF), welches logische Aussagen über beliebige Dinge als Tupel von Subjekt-Prädikat-Objekt (siehe Abbildung 1), sogenannten Tripeln, darstellt (Balaji et al. 2018b). Im Rahmen des Projekts wurde die BRICK-Ontologie verwendet, um Wissen über die Gebäudetopologie, seine HLKK-Systeme sowie deren Datenpunkte zu strukturieren.

Abbildung 1: Grundlegendes RDF-Diagramm



BRICK ist ein auf Open-Source-Ontologie basierendes einheitliches Metadatenschema, das physische, logische und virtuelle Einheiten und ihre Beziehungen semantisch beschreibt. Die standardisierte Ontologie ist erweiterbar und sorgt für ein flexibles Datenmodell, das sich problemlos in bestehende Tools und Datenbanken integrieren lässt.

Als Ontologie wird eine hierarchische Ordnung bzw. Struktur von Klassen, Beziehungen und dessen Eigenschaften, also eine formale Darstellung von Wissen verstanden. Die Nutzung einer Ontologie kann zur Erstellung eines semantischen Datenmodells führen. Das semantische Datenmodell wiederum ist die Beschreibung eines Objekts oder Systems durch Instanzen unterschiedlicher Klassen, welche in einem bestimmten Zusammenhang (Beziehung) zueinanderstehen können (z.B. GAS). Das Open-Source Projekt BRICK ermöglicht die Beschreibung von physischen, logischen und virtuellen Objekten der technischen Gebäudeausrüstung und deren Beziehungen zueinander mit Hilfe von semantischer Webtechnologie. Die vordefinierte Ontologie ist erweiterbar und gewährleistet damit ein flexibles Datenmodell, welches sehr gut in Datenbanken integrierbar ist.

Im Projekt soll das Datenmodell als Ablage statischer Information dienen, welche beispielsweise für Suchabfragen innerhalb der ausgewählten Algorithmen ihre Anwendung finden (siehe Konzept des Software-Frameworks - Kapitel 4.4). BRICK besteht aus den folgenden Klassen, welche für die Erfassung von physischen, logischen und virtuellen Entitäten (= Objekte) herangezogen werden:

- Collection (z.B. HLK-Teilsystem, hydraulischer Kreislauf, Photovoltaikfeld oder Gebäudeportfolio)
- Equipment (z.B. elektrische, anlagen-, licht- und sicherheitstechnische Ausrüstung, Ventil)
- Location (z.B. Gebäude, Stockwerk, Zone, Raum, Außenbereich)
- Measurable (z.B. Menge, Substanz)
- Point (z.B. Alarm, Befehl, Parameter, Sensor, Sollwert, Status)

Hierbei repräsentieren physische Entitäten alle Objekte welche physische Präsenz aufweisen. Virtuelle Entitäten basieren auf Software und deren Verarbeitung (z.B. Sensorstatus, Soll- und Geber-Werte,

Zählerpunkte) und logische Entitäten sind über einen Satz von Regeln definiert (z.B. Raumzonierung). Innerhalb dieser Klassen sind Subklassen vertreten, welche zu einer verbesserten Auswahl der geeigneten Instanz verhelfen. Die Instanzen der Klassen werden mit sogenannten „Relationships“ zueinander in Beziehung gesetzt. Diese können auf drei unterschiedliche Arten entsprechende Zusammenhänge darstellen:

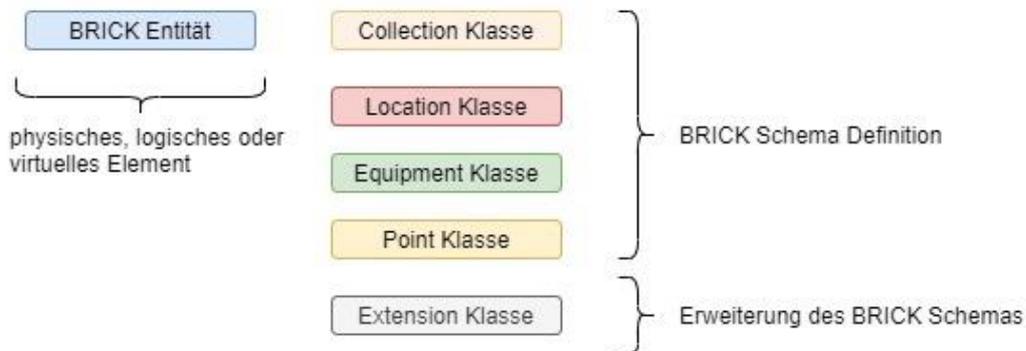
Komposition: hierbei können zwischen physischen und logischen Kompositionen unterschieden werden. Eine physische Komposition besteht beispielsweise aus mehreren Equipments, welche als Verbund ein neues Equipment definieren (z.B. Lüftungsanlage). Gleiches gilt für Locations (z.B. Stockwerk, welches aus den entsprechenden Räumen aufgebaut ist). Demgegenüber stehen logische Kompositionen (z.B. Zonierung von Räumen).

Topologie: darunter versteht man die Anordnung bzw. Reihenfolge, in welcher Ausrüstungsgegenstände bzw. Gebäudeteile miteinander verknüpft werden und deren Einwirkung auf den Durchfluss von Versorgungsmedien.

Telemetrie: dient zur Assoziation zwischen Datenquellen (-punkten) und ihren physischen, logischen oder virtuellen Entitäten.

Die nachfolgende Abbildung 2 zeigt den grundsätzlichen Aufbau des Datenmodells. Zum besseren Verständnis der einzelnen Klassen erfolgt eine Farbkennzeichnung.

Abbildung 2: Legende verwendeter BRICK Klassen



# 4 Projektinhalt

## 4.1. Use Case Anforderungsanalyse

### 4.1.1. Beschreibung der Use Cases

Im Rahmen einer Anforderungsanalyse wurden zunächst technische Anforderungen für das angedachte KI-Tool spezifiziert. Hierfür wurden Anwendungsfälle, im Folgenden Use Cases (UC) genannt, definiert und in zwei Bereiche für die Untersuchung unterteilt. Die UC1 und UC2 wurden dem Energiemanagement sowie UC3 der Instandhaltung zugeordnet. Eine detaillierte Beschreibung der Use Cases sind dem Anhang zu entnehmen. Nachstehend wird ein kurzer Überblick über zu bearbeitende Use Cases gegeben.

Use Case 1: Wärme- & Kälteversorgung: Optimierung der Energiebereitstellung von Brunnen- und Wärmepumpenanlage durch prädiktive Vorhersage des Gebäudelastverhaltens und Empfehlung des effizientesten Betriebsmodus unter Einhaltung der behördlichen Auflagen zur Grundwassernutzung.

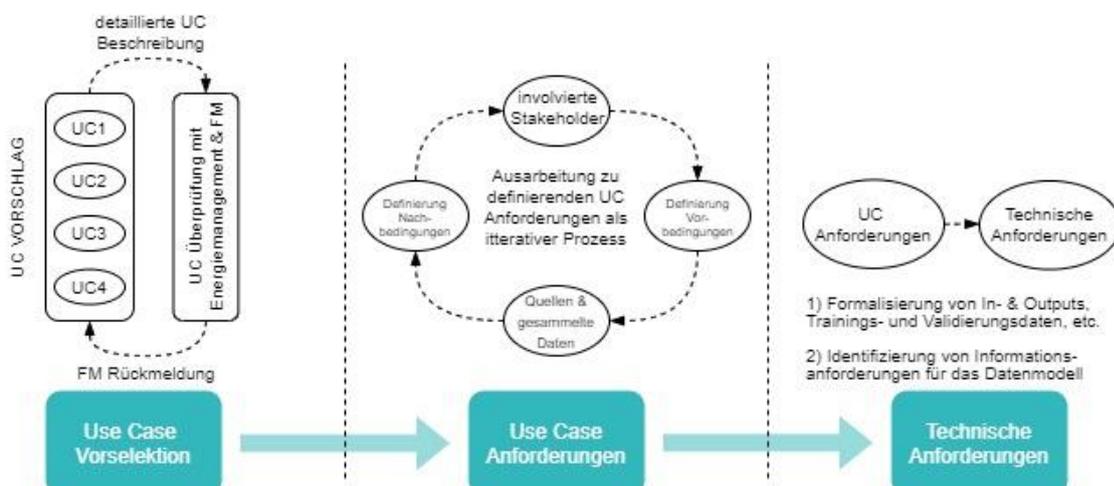
Use Case 2: Wärme- & Kälteabgabe: Optimierter Betrieb der Betonkernaktivierung unter Berücksichtigung des Energieverbrauchs und der thermischen Behaglichkeit.

Use Case 3: KI-gestützte Fehlererkennung im Gebäudeautomationssystem (Ventilstellungen Heizen / Kühlen, elektrische Energieverbräuche, Komponenten, etc.) und Visualisierung für weiterführende Inspektion durch den Betreiber

### 4.1.2. Methodische Vorgehensweise der Anforderungsanalyse

Wie in Abbildung 3 dargestellt, wurde eine partizipative Methodik gewählt, um vordefinierte UC-Anforderungen (für jeden UC) und deren technische Anforderungen für das KI-Tool auszuarbeiten.

Abbildung 3: Partizipationsprozess des Anforderungsspezifizierung



Zunächst wurde jeder vorgeschlagene Use Case mit dem Facility Management (FM) hinsichtlich technischer Machbarkeit und Relevanz geprüft. Dies führte zu einer Präzisierung der jeweiligen Use Case-Beschreibungen. Im nächsten Schritt wurden die UC-Anforderungen erhoben. Dazu wurde eine Liste mit vordefinierten Anforderungen erstellt, aufgezeigt in Tabelle 2, um die Use Cases detailliert zu beschreiben.

Tabelle 2: Use Case Anforderungen

UC Anforderungen	Beschreibung
<b>Beschreibung</b>	Dieser Abschnitt enthält eine detaillierte Beschreibung dessen, was im Use Case geschieht.
<b>Nicht-Ziele</b>	Auflistung von Aufgaben, welche thematisch involviert und möglicherweise nützlich sind, im Use Case aber nicht behandelt werden.
<b>Stakeholder / Akteure</b>	Personen oder Rollen außerhalb des beschriebenen Anwendungsfalls (z. B. Servicetechniker, Betreiber, Energiemanager, Facility Manager). Die Akteure werden in einem eigenen Abschnitt vorgestellt und können in zwei Typen unterteilt werden. Ein primärer Akteur ist der eigentliche Benutzer. Der sekundäre Akteur spielt eine Rolle als „unterstützender Akteur“, der das System überwacht und wartet.
<b>Vorbedingungen</b>	Alle Bedingungen, die erfüllt sein müssen, damit der Use Case ausgeführt werden kann. Wenn keine Vorbedingungen vorliegen, wird „keine“ geschrieben. Folgende Unterteilungen werden vorgenommen: <ul style="list-style-type: none"> <li>• Externe Daten: Eingabeinformationen, die zum Starten und Ausführen des Anwendungsfalls erforderlich sind</li> <li>• Betriebsdaten: Überwachungsdaten des Gebäudeautomationssystems (wie Lastprofile, Raumbedingungen usw.)</li> <li>• Prozessbezogene Daten: Diese Informationen beschreiben, unter welchen Bedingungen dieser Anwendungsfall funktioniert oder nützlich ist. Der Zustand, in dem sich das System befinden muss, damit der Use Case funktionsfähig oder nützlich ist.</li> </ul>
<b>Nachbedingungen</b>	Der Zustand des Systems oder die konkrete Bedingung, die nach erfolgreicher Ausführung des Anwendungsfalls erwartet wird.
<b>Prozessfluss</b>	Hier wird das typische Szenario dargestellt, welches leicht zu verstehen ist bzw. der häufigste Fall ist. An dessen Ende steht die Zielerreichung des Hauptakteurs/Use Cases.
<b>Nutzen</b>	Technischer und wirtschaftlicher Nutzen des Use Cases aus Unternehmenssicht.
<b>KI Methode</b>	Die Auswahl der Methode(n), die sich aus den Anforderungen des Use Cases ergibt

Basierend auf der Anwendungsfallbeschreibung wurden die Anforderungen gemeinsam mit dem FM (Geschäftsentwicklung, Energiemanagement, Betrieb) in einem iterativen Prozess diskutiert. Als letzter Schritt wurden aus den UC-Anforderungen technische Anforderungen formuliert.

Im Rahmen des Partizipationsprozesses wurden innerhalb der Anforderungsanalysen ebenfalls projektrelevante Problemstellungen identifiziert. Da die Wartung der Hauptkomponenten wie beispielsweise Wärmepumpen- oder Lüftungsanlage(n) sowie Rückkühlwerk und Pumpengruppen von externen Servicedienstleistungen abgewickelt wird, deren Datenpunkte somit keine Verbindung mit dem Gebäudeautomationssystem aufweisen und laut dem FM nur marginale Aufzeichnungen betreffend ihre Fehlermeldungen vermerkt waren, mussten dementsprechende Anpassungen bei den Use Case-Beschreibungen erfolgen. Diese notwendige Revidierung der Use Cases für die Instandhaltung brachte einen Use Case hervor, welcher die Erkennung von Anomalien bzw. anormalen Verhalten innerhalb des Gebäudeautomationssystems als Ziel hatte.

## **4.2. Datenerhebung**

### **4.2.1. Demonstrationsgebäude**

Zum Zwecke der Datenerfassung, Anlagenüberwachung, Modellvalidierung sowie Use Case Evaluierung wurde ein Bürogebäude als Testumgebung ausgewählt. Hierbei handelt es sich um ein vierstöckiges Forschungs- und Bürogebäude am Standort Wien, Österreich.

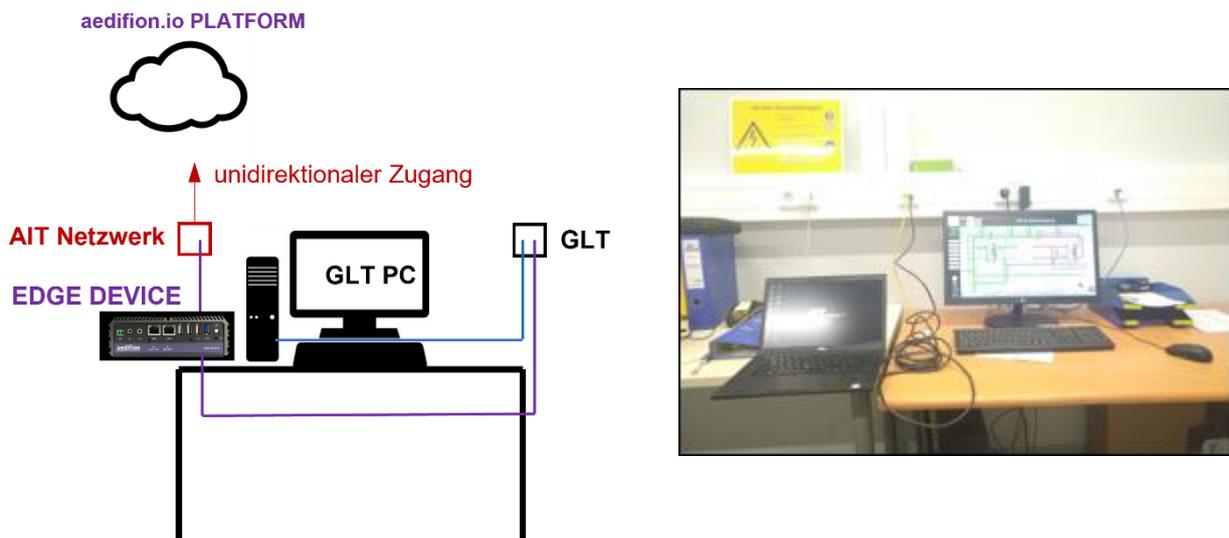
Die primäre Wärme- bzw. Kältebereitstellung erfolgt mittels Wasser-Wasser-Wärmepumpe wobei die Brunnenanlage behördlich festgelegten, täglichen sowie jährlichen Grundwasserentnahmen und deren Rücklauftemperaturen einzuhalten hat. Das Objekt selbst besteht aus sechs Geschossebenen, welche vom Untergeschoss bis zum vierten Obergeschoss verlaufen. Für die Use Case Betrachtungen untersuchte man Büro- und Besprechungsräume des ersten und dritten Obergeschosses. Die Büros sind in entsprechende Zonenabschnitte unterteilt und ausgeführt worden. Der benötigten Wärme- oder Kältebedarf wird in Form einer thermisch aktivierten Betondecke an die jeweilige HLK-Zone mittels Change-Over-Schaltung zugeführt

### **4.2.2. Anlagenmonitoring**

Zur Umsetzung einer laufenden Erfassung und Archivierung der über BACnet / IP adressierten Datenpunkte wurde entschieden einen Cloud Plattform anzuwenden. Hierfür wurde eine Software-As-A-Service Dienstleistung als Drittleister (aedifion GmbH) beauftragt, welche die Datenpunkte des GAS überwachte. Um eine Verbindung mit der Cloud Plattform herstellen zu können musste ein Edge Device innerhalb des hausinternen Netzwerks installiert werden. Das Gerät wurde mit BACnet / IP und dem hauseigenen Intranet verbunden (siehe Abbildung 4) und eine unidirektionale Verbindung nach außen durch Portfreischaltung ermöglicht.

Über eine browserbasierte Umgebung zur kundenseitigen Datenvisualisierung konnten sämtliche Datenpunkte selektiert und über Plots dargestellt werden, welche eine Überprüfung des Anlagenbetriebs ermöglichte. Die Aufzeichnung der Datenpunkte des GAS sowie deren Datenspeicherung erfolgte während der gesamten Projektlaufzeit bis einschließlich Juni 2024.

Abbildung 4: Installation Edge Device (im GLT PC Raum)



### 4.2.3. IoT Netzwerk

Um fehlende Information über das thermische Raumverhalten von Büro- und Meetingräumen zu erhalten, wurde ein lokales Funknetzwerk bestehend aus kostengünstigen IoT Sensoren installiert. Für das IoT-Netzwerk wurde auf das Kommunikationsprotokoll ZigBee zurückgegriffen. Die Wahl von ZigBee hängt von der Struktur seiner Kommunikation ab. ZigBee-Geräte können miteinander über verschiedene Netzwerkschemata verknüpft werden. ZigBee zeichnet sich dabei durch sein Mesh-Netzwerkschema aus. In einem Sternnetzwerk kommunizieren alle vernetzten Geräte über einen zentralen Knotenpunkt miteinander. Im Gegensatz dazu ermöglicht das ZigBee-Mesh beliebige Verbindungen.

Im ZigBee-Netzwerk (Mesh) agiert jedes dauerhaft stromversorgte Gerät als Repeater. Plugs und ähnliche Geräte können das Signal flexibel weiterleiten. Diese Netzwerktopologie reduziert das Ausfallen von Sensoren, da sich jeder batteriebetriebene Sensor notfalls mit jedem Repeater in Reichweite verbinden kann. Mit Geräten die auch als Sender fungieren, wird Reichweite des ZigBee-Netzwerks erweitert. Hingegen leiten batteriebetriebene Geräte wie Temperatur- und Bewegungssensor das Signal aufgrund ihres höheren Energiebedarfs nicht weiter. Die Reichweite von Gateway bzw. Repeater bis Sensor beträgt innerhalb eines Gebäudes circa 15 Meter.

Ein Raspberry Pi 4 dient als Datenlogger und kombiniert mit dem Gateway ConBee II Stick als Zentrum des Netzwerks. Auf dem Raspberry Pi ist Home Assistant OS als Betriebssystem installiert. Home Assistant ist eine open source Software zur Hausautomation und über Integrations oder Apps mit allen gängigen IoT-Protokollen vereinbar. Über die Home Assistant Oberfläche lassen sich die Verbindungen zu den Sensoren sowie die dazugehörige Parametrierung durchführen. Mit Home Assistant lassen sich auch automatisiert Backups der Verbindungen und Messdaten der Sensoren erstellen.

Bei der Auswahl der Sensoren wurden die positiven Erfahrungen mit den Develco Products ausschlaggebend. Die White-brand ZigBee Sensoren bieten eine preisgünstige aber qualitativ hochwertige Lösung für Projekte, bei denen mehrere hunderte Sensoren gebraucht werden. Bei Frient Sensoren

handelt es sich um dieselben Produkte die zwecks White-brand nun unter einem anderen Markennamen gekauft wurden. Die folgende Tabelle gibt Aufschluss über die Arten der Sensoren, welche für die Messung verwendet wurden:

Tabelle 3: verwendete IoT-Sensoren

Sensor	Marke	Typ	Größe
Hybridsensor	Develco	AQSZB-110	Temperatur, VOC, rel. Luftfeuchtigkeit
Hybridsensor	Frient	AQSZB-110	Temperatur, VOC, rel. Luftfeuchtigkeit
Kontaktsensor	Develco	WISZB-120	Magnet. Kontakt, Temperatur
Kontaktsensor	Frient	WISZB-121	Magnet. Kontakt, Temperatur
Bewegungssensor	Frient	MOSZB-140	Belegung, Helligkeit, Temperatur
Smart Plug	Develco	SPLZB-132	Repeater-Funktion

Im Projekt wurden in 41 Räumen auf zwei Stockwerken der FutureBase insgesamt 258 Sensoren installiert. Dabei wurden folgende Sensoren verwendet:

- Bewegungssensoren: Oberhalb der Türen zur Erfassung von Lichtveränderungen, Temperatur und Belegung.
- Hybridsensoren: Rechts oder links der Türen auf Augenhöhe zur Messung von Temperatur und Luftfeuchtigkeit, geschützt vor direktem Sonnenlicht.
- Tür- und Fenstersensoren: Am Rahmen angebracht zur Erfassung von Öffnungs- und Schließvorgängen sowie Temperaturveränderungen.

Zur Signalweiterleitung wurden in etwa jedem dritten Raum Smart Plugs als Repeater installiert. Ein Raspberry Pi mit Gateway verbindet die Netzwerke. Die Messungen konzentrieren sich auf das 1. und 3. Stockwerk:

- 1. Stockwerk (West): Besprechungszimmer mit besonderer Nutzung und Regelung.
- 1. und 3. Stockwerk (Ost): Typische Regelbüros.
- 

In Regelbüros wurde pro Raum ein Hybridsensor, ein Bewegungssensor sowie je Tür und Fenster ein Eintrittssensor installiert. Große Besprechungszimmer erhielten zwei Hybridsensoren und zwei Bewegungssensoren.

#### **4.2.4. Störbehebungen IoT Netzwerk**

##### Konnektivitätsprobleme

Um Zeit zu sparen, wurden die Sensoren zunächst an Mitarbeiterarbeitsplätzen mit dem Gateway gekoppelt und anschließend in den Zielräumen montiert. Dabei traten Verbindungsprobleme auf, da ZigBee und WiFi auf ähnlichen Frequenzen arbeiten und sich Kanäle überlappen. Nach der Kopplung wurden die Verbindungsdaten gespeichert, wodurch die Sensoren später schnell erneut mit ihren Label-Nummern verknüpft werden konnten.

##### Netzwerkaufbau

Die geplanten 258 Sensoren für zwei Stockwerke lagen zahlenmäßig unter der maximalen Kapazität von 500 Verbindungen eines ConBee II Gateways. Ein Plug-Repeater reichte empirisch aus, um ein Netzwerk über zwei Etagen am Standort aufzubauen. Allerdings scheiterten Versuche, die Verbindung zwischen dem ersten und dritten Stockwerk mit zwei Plugs herzustellen. Dies könnte an einer Abschirmung der Datensicherheitsbüros im dritten Stock liegen. Daher wurde entschieden, ein zweites unabhängiges Netzwerk mit derselben Konfiguration aus Raspberry Pi 4 und ConBee II Gateway für das dritte Stockwerk einzurichten.

IoT Netzwerk 1.Stock: bestehend aus 164 Sensoren

IoT Netzwerk 3.Stock: bestehend aus 94 Sensoren

##### **Stromausfall**

Normalerweise kann sich ein ZigBee-Netzwerk nach einem Stromausfall selbstständig wieder aufbauen, da die Verbindungsdaten im Gateway gespeichert sind. Während des Messzeitraums traten jedoch bei zwei Stromausfällen Probleme auf:

Erster Stromausfall: Nach dem Stromausfall waren einige Messdaten, insbesondere die Lux-Werte, verzerrt. Das Problem konnte durch eine schnelle Rekonfiguration der betroffenen Sensoren behoben werden.

Zweiter Stromausfall: Alle Sensoren im ersten Stockwerk verloren die Verbindung zum Gateway. Aufgrund des Stromausfalls wurden offenbar die digitalen Ports des Raspberry Pi vertauscht, wodurch sich das Netzwerk nicht neu aufbauen konnte. Zur Lösung wurde die ZigBee Home Automation (ZHA) Verbindung an die Gateway-ID gekoppelt, um künftige Port-Tausch-Probleme zu vermeiden. Anschließend mussten einige Sensoren manuell neu gekoppelt werden.

##### **Korruption SD-Karte**

Nach dem Totalausfall des IoT-Netzwerks im 1. Stock, wurden LAN-Kabel, Port und der Raspberry Pi selbst erfolgreich auf dessen Funktion überprüft. Ursache war die Korruption der 32 GB SD-Karte, auf der das Betriebssystem Home Assistant installiert war. Die genauen Umstände der Korruption konnten nicht aufgeklärt werden, können aber mit den Folgen der Stromausfälle zu tun haben. Die SD-Karte musste ausgetauscht und die Sensor-Verbindungen erneut verbunden werden.

Beim Aufbau eines IoT-Netzwerk gilt es also neben dem korrekten Aufbau des Netzwerks auch ein großes Augenmerk auf die genauen Verbindungsdaten zu setzen. Das Abspeichern der Messdaten,

aber vor allem der Verbindungs-Daten und der dazugehörigen Nummerierung der Sensoren in regelmäßigen Back-Ups beugt gegen Datenverlust und zeitaufwendige Verbindungsarbeiten vor.

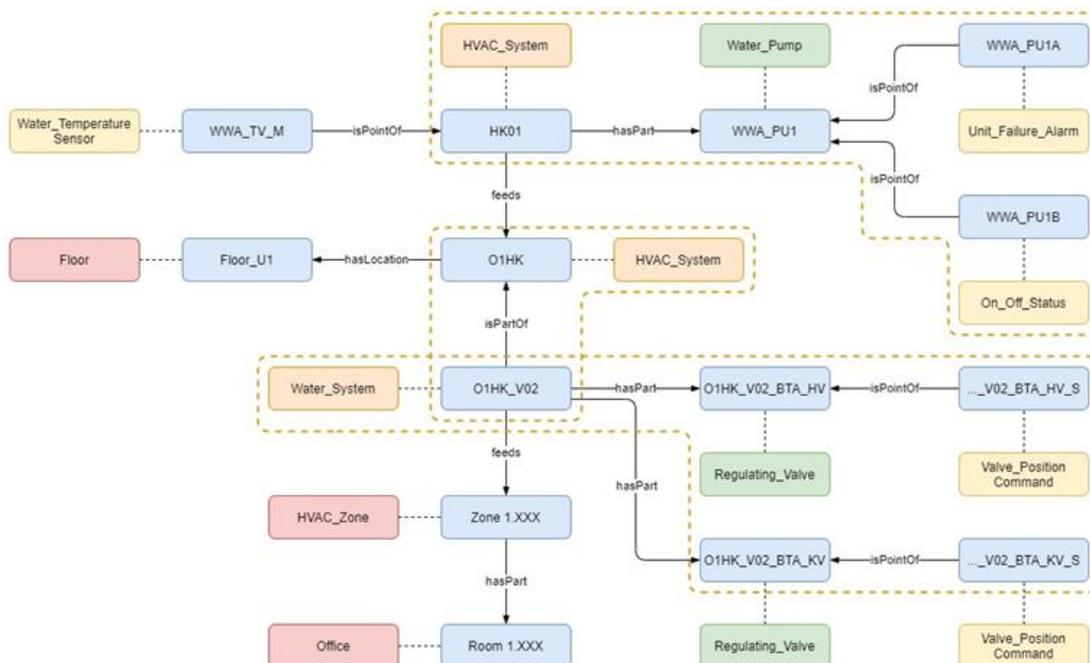
### Ausfall Sensoren

Nach dem wiederaufgebauten Netzwerk konnten einige der Sensoren nicht oder nur teilweise wieder mit dem Gateway verbunden werden. Auch einige der im Use Case 2 des AP5 betrachteten Sensoren waren von dem Ausfall betroffen. Die defekten Sensoren wurden durch neue ersetzt. Dabei mussten die bisher gemessenen Daten mit den Daten der neu eingesetzten IOT-ID's abgestimmt werden.

## 4.3. Semantisches Datenmodell

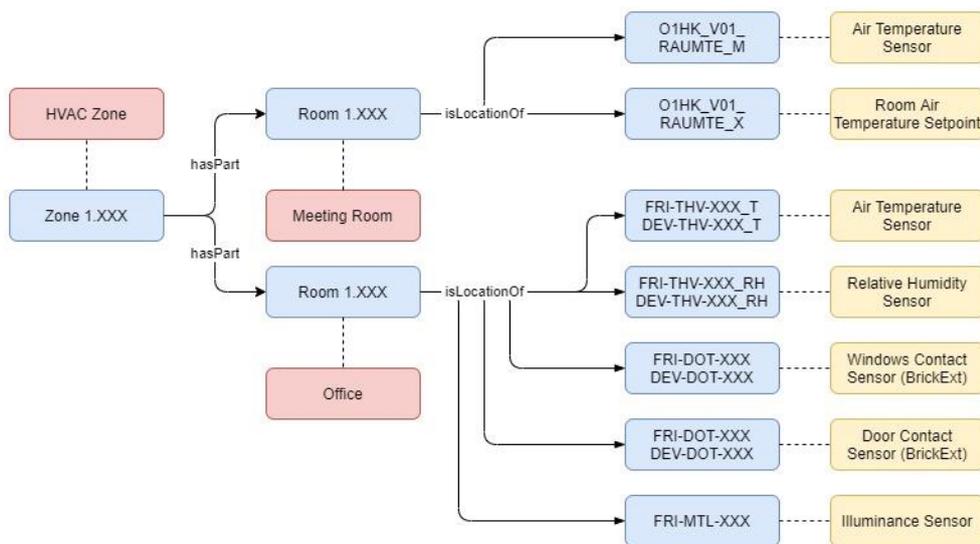
Abbildung 5 zeigt einen Teilbereich des Datenmodells für das GAS. Das Subsystem HK01 stellt das Hauptwärme-/Kälteversorgungssystem dar. HK01 versorgt O1HK, das sich in Etage\_U1 befindet und O1HK\_V02 enthält, ein hydraulisches System zur Betonkernaktivierung. Innerhalb jedes Subsystems befinden sich Equipments (Kühler, Pumpen usw.) und Points (Sensortypen usw.), welche zueinander semantisch in Verbindung stehen. Beispielsweise besteht O1HK\_V02 aus zwei Regelventilen zur Steuerung des Volumenstroms des Heiz- (O1HK\_V02\_BTA\_HV) oder Kühlventils (O1HK\_V02\_BTA\_KV). Diese Ventile enthalten wiederum Datenpunkte wie einen Ventilpositionsbefehl.

Abbildung 5: BRICK Datenmodell (Auszug HLK-Systeme innerhalb des GAS)



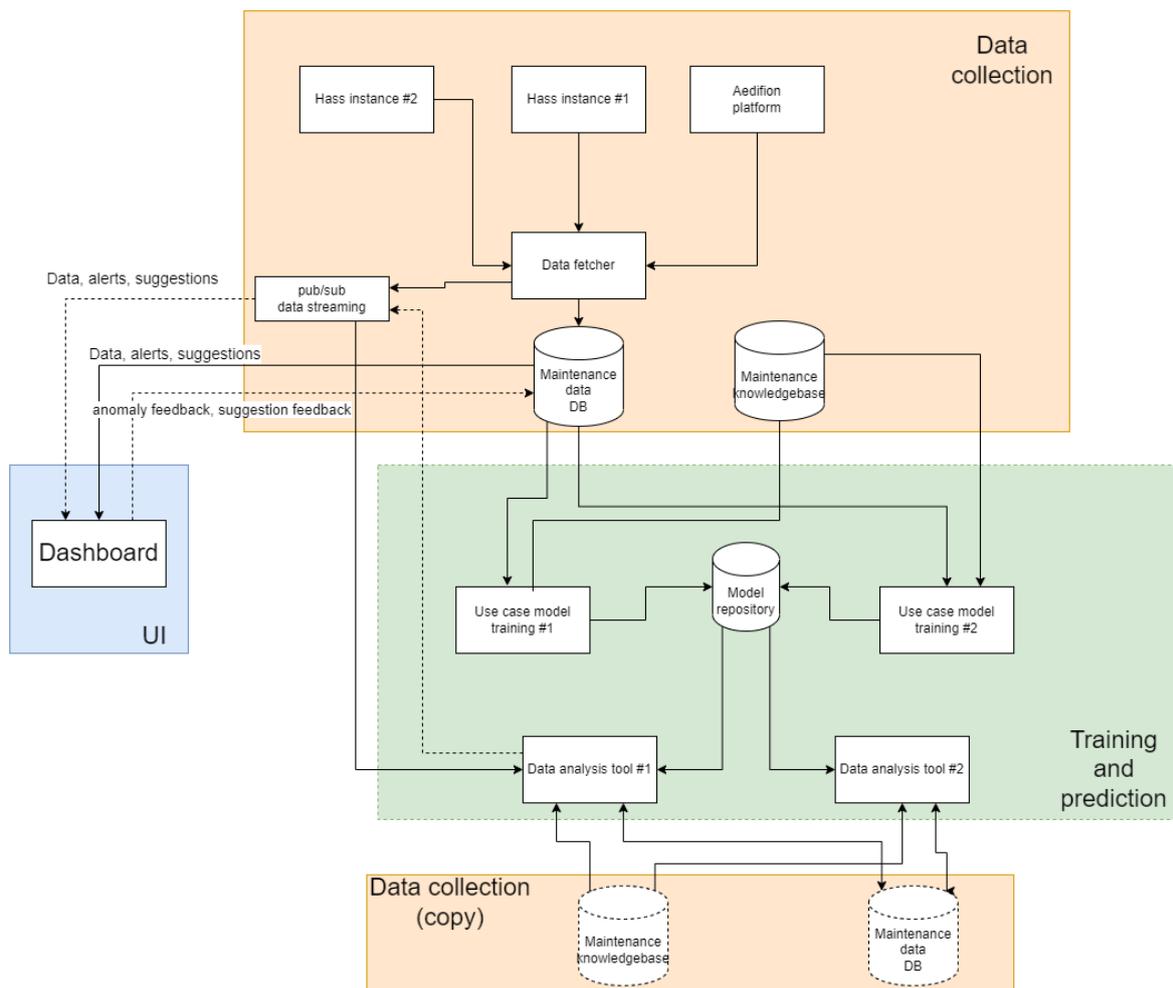
Eine Übersicht über die Datenmodellstruktur in Bezug auf das IoT-Sensornetzwerk ist in Abbildung 6 dargestellt. Hier werden die installierten Sensorgeräte für einen Büroraum dargestellt. Eine HLK-Zone, die eine logische Einheit ist, um mehrere Räume miteinander zu verbinden, ordnet Besprechungsräume und Büros an. In diesen Büros sind verschiedene IoT-Sensortypen (Temperatur, Luftfeuchtigkeit, Kontakt, Beleuchtungsstärke) platziert. Die Sensoren selbst enthalten die Metadaten ihrer Einheit.

Abbildung 6: BRICK Datenmodell (Auszug des IoT Sensornetzwerks)



## 4.4. Konzept Softwareframework

Abbildung 7: Konzept zur Kommunikation zwischen den Komponenten



Die Abbildung 7 veranschaulicht das Konzept der angedachten Systemkomponenten und ihrer Verbindung zueinander. Das Diagramm teilt sich in folgende drei farblich hinterlegte funktionelle Bereiche auf:

- Komponenten der Datenerfassung (orange)
- Komponenten der Datenanalyse (grün)
- Komponenten der Interaktion bzw. Benutzeroberfläche (blau)

Hass Instanzen 1 und 2 repräsentieren Home Assistant Anwendungen bzw Gerätschaften (IoT), welche im ersten und dritten Stock der FUTUREbase eingesetzt werden. Jede Instanz beinhaltet sowohl die notwendige Rechen- als auch Speicherinfrastruktur (durch einen Raspberry Pi). Hierbei stellt nur die Datenspeicherfähigkeit eine gewisse Herausforderung bzw. Besorgnis dar.

Die Aedifion Plattform stellt jene Datenplattform dar, welche Datenerfassung und -aufzeichnung des Gebäudeautomationssystems übernimmt (über Cloud als SAAS). Die Daten aller drei Datenquellen werden in der mAIntenance Datenbank durch einen Datenabrufers gesammelt, vereinheitlicht und gespeichert. Darüber hinaus werden Metadaten zu gesammelten Datenpunkten in der Wissensdatenbank gespeichert, welches durch einen Triple Store mit zugehöriger Reasoning Engine realisiert wird.

Der Datenabrufers kann gesammelte Daten auch an den Publish/Subscribe-Bus übertragen, wo Clients (Datenanalyse) Aktualisierungen von bestimmten für sie relevanten Sensoren abonnieren und nahezu in Echtzeit auf Änderungen reagieren können. Der Pub/Sub-Bus ermöglicht es Datenanalyse, Warnungen und Vorschläge an interessierte Kunden zu übermitteln.

Es können hierbei unterschiedliche Ansätze zur Bedienung der verschiedenen Bereiche erfolgen. Das Datenanalysetool #1 sendet ungewöhnliche Ergebnisse der Datenanalyse (Warnungen, Anomalien, ...) über pub/sub bus, dargestellt als punktierte Linie, welche über die Push-Methode verfügbar wird, und speichert sie zudem in der mAIntenance Datenbank ab. Während Datenanalysetool #2 nur in der Datenbank seine Ergebnisse speichert und diese über die Pull-Methode zur Verfügung stellt. Modelle des maschinellen Lernens werden für jeden Anwendungsfall (UC1-UC3) in separaten Arbeitsabläufen trainiert (UC Modelltraining), und die trainierten Modelle im Modell-Repository gespeichert. Aus diesem Speicher können Sie im Anschluss von den jeweiligen Datenanalysetools genützt werden.

Die beiden erwähnten Ansätze des Arbeitsablaufs (Push/Pull) finden ihre Anwendung zur Bedienung der Datenanalyseedienste. Beim Push-Ansatz wird von den Datenanalyseediensten jeder neue Sensormesswert verarbeitet, um nahezu augenblicklich auf Ereignisse reagieren zu können. Der Pull-Ansatz führt die Datenanalyseedienste nur zu bestimmten Zeiten aus (bzw. manuell oder durch externe Ereignisse) und verarbeitet dabei alle verfügbaren Daten bzw. neue Daten. Je nach Anwendungsfall wird hier basierend auf den funktionalen und nicht-funktionalen Anforderungen der entsprechende Ansatz für den spezifischen Use Case ausgewählt.

## **4.5. Modellentwicklung**

### **4.5.1. Machine Learning Modelle - Use Case 1**

Use Case 1 wurde nach etablierten Methoden der Zeitreihenvorhersage aufgebaut (siehe z.B. Amasyali and El-Gohary 2018 oder Deb et al. 2017b) und basiert auf manuell in den Daten des GAS identifizierten Zeitreihen, darunter

- Energien und Leistungen, Volumina und Volumenströme, Vor- und Rücklauftemperaturen sowie Ventilpositionen im Kühl-, Heiz-, Serverraum- und Grundwasserkreislauf,
- elektrische Energien und Leistungen sowie Vor- und Rücklauftemperaturen der Heiz- und Kühlseite der Wärmepumpe sowie die Steuersignale an letztere,
- die Außentemperatur und -luftfeuchtigkeit, und
- Regelgrößen: der Betriebsmodus (Heizen, Übergangsmodus, Kühlen), der Ausbaugrad (Kühlung über Grundwasser oder Wärmepumpe) sowie die Grenztemperaturen der Betriebsmodi.

Darüber hinaus wurden historische Wetterdaten von Meteonorm verwendet. Die abgerufenen Daten wurden mittels der Python-Bibliothek Pandas eingehend untersucht und diversen Verbesserungen unterworfen (30min-Zeitraster einführen, Ausreißer entfernen, fehlende Werte auffüllen uvm.). Die Machine Learning (ML)-Modelle wurden mittels der Python-Bibliothek Darts erstellt. Mit dieser wurden die Größen in drei Gruppen eingeteilt:

- Targets: elektrische Leistung (Wärmepumpe, Rückkühler, Regelung), Grundwasser-Volumenstrom
- Zukunfts-Features (in der Vergangenheit und Zukunft bekannt): u.a. Regelgrößen (Betriebszustand, Ausbaugrad und Grenztemperaturen)
- Vergangenheits-Features (nur in der Vergangenheit bekannt): u.a. Energie und Leistung, Volumen und Volumenstrom, Vor- und Rücklauftemperatur

Die Targets wurden im Verhältnis 3:1 in Trainings- und Validierungsdaten aufgeteilt. Weniger nützliche Features wurden mittels „Mutual Information“ mit den Targets identifiziert und verworfen. Mit den Features und Targets wurden ML-Modelle für Vorhersagen für einen Tag in die Zukunft trainiert (gesamtes Zeitraster, alle 4 Targets).

Trainiert wurden drei Darts-Modelltypen: eine lineare Regression, ein Light Gradient Boosting-Modell und ein Extreme Gradient Boosting-Modell, jeweils mit 30min, 1h, 2h, 3h, 6h, 12h, 1d als Verzögerungen für die Targets und die Zukunfts- und Vergangenheits-Features. Für die restlichen Hyperparameter der Modelltypen wurden die Standardwerte verwendet. Die Modelle wurden jeweils mit den Trainingsdaten trainiert und den Validierungsdaten beurteilt: Über die gesamte Validierungsperiode wurde an jedem Tag eine Vorhersage erstellt und die Einzelvorhersagen zu einer kontinuierlichen Zeitreihe verbunden. Zur Beurteilung wurde der Root Mean Square Error zwischen der vorhergesagten und der Validierungs-Zeitreihe berechnet. Die drei ML-Modelle wurden mit einem Baseline-Modell verglichen, bei dem als Vorhersage die Werte des vorhergehenden Tages wiederholt wurden.

Optimierte Werte der Regelgrößen wurden mittels einer relativ einfachen Methodik ermittelt: Für jede Regelgröße wurde eine Menge erlaubter Werte definiert. Diese Werte wurden im ML-Vorhersageschritt als Eingabewerte verwendet, indem die entsprechenden Zukunfts-Features am vorherzusagenden Tag angepasst wurden (selber Wert an allen Zeitpunkten in der Zukunft). Anschließend wurde für jede Kombination von Werten der Regelgrößen eine Vorhersage getroffen, und es wurde diejenige Kombination identifiziert, die den niedrigsten Energieverbrauch unter Einhaltung der Grundwasserentnahmeauflagen aufwies. Die Werte der Regelgrößen der so identifizierten Vorhersage stellten dann die optimierten Werte dar. Diese Optimierungsprozedur wurde lediglich beispielhaft demonstriert und nicht rigoros untersucht.

#### 4.5.2. Machine Learning Modelle - Use Case 2

Die Methodik dieses Use Cases ist ähnlich derjenigen für Anwendungsfall 1, nur dass nicht das Gebäude als Ganzes, sondern viele einzelne Räume betrachtet wurden. Zur Bestimmung der je Raum notwendigen Daten wurde das semantische Gebäudemodell verwendet. Zur Extraktion der relevanten Informationen aus dem Modell wurde in Arbeitspaket 4 ein einfacher „Reasoner“ in *Pandas* erstellt, der aus den folgenden Schritten besteht:

- Es werden alle Subjekt-Prädikat-Objekt-Tripel aus dem semantischen Modell abgerufen.
- Es werden alle Objekte gefunden, die direkt zu einem Subjekt gehören. Hierbei werden auch invertierte Beziehungen berücksichtigt, d.h. mit dem Objekt als Subjekt und umgekehrt und wie folgt invertiertem Prädikat: beispielsweise isFedBy ↔ feeds
- Es werden rekursiv alle Objekte gefunden, die indirekt zu einem Subjekt gehören. Die Rekursion wird bei bestimmten Objekten und -typen abgeschnitten und andere Objekte und -typen werden nachträglich ausgeschlossen.
- Es werden alle Sensoren einer HLK-Zone gefunden. Für jeden Sensor wird das Behälter-Element (Raum, Wassersystem etc.), der Sensor- und Behälter-Typ, die Maßeinheit und die Beschreibung ermittelt.

Die eigentlichen Daten stammten aus dem Gebäudeautomationssystem, aus dem IoT-Sensornetzwerk sowie von dem Wetterdaten-Service *OpenMeteo*. Die abgerufenen Daten wurden wie in Anwendungsfall 1 eingehend untersucht und mithilfe von *Pandas* diversen Verbesserungen unterworfen (hier: 15min-Zeitraster einführen, Ausreißer entfernen, fehlende Werte auffüllen, neue Größen berechnen uvm.) und abschließend per Raum organisiert.

Für die ML-Modelle wurden die Größen mittels *Darts* für jeden Raum in drei Gruppen eingeteilt:

- Targets: Raumtemperatur, Raumluftfeuchtigkeit, Temperatur der Betonkernaktivierung
- Zukunfts-Features: u.a. Raumeinfluss kühlen & heizen, Wetter (Temperatur, Luftfeuchtigkeit, Wind, Strahlung, Niederschlag)
- Vergangenheits-Features: u.a. Informationen zur Betonkernaktivierung (Ventilstellungen, Temperatursollwerte), zum Raum (Temperatur, Tür- und Fensterkontakt)

Mit diesen Daten wurden für jeden Raum ein Trainings- und ein Validierungszeitraum festgelegt und jeweils ein ML-Modell trainiert, in diesem Fall für *drei* Tage in die Zukunft und mit Verzögerungen für alle Zeitrasterwerte an einem, zwei und sechs Tagen vor dem Vorhersagezeitraum. Räume mit fehlenden Targets wurden verworfen. Das Training, die Vorhersage und die Beurteilung wurden wie in Anwendungsfall 1 durchgeführt, mit dem Unterschied, dass das Baseline-Modell den letzten Tag jeweils dreimal wiederholte und dass lediglich der Light Gradient Boosting-Modelltyp von *Darts* betrachtet wurde.

### 4.5.3. Machine Learning Modelle - Use Case 3

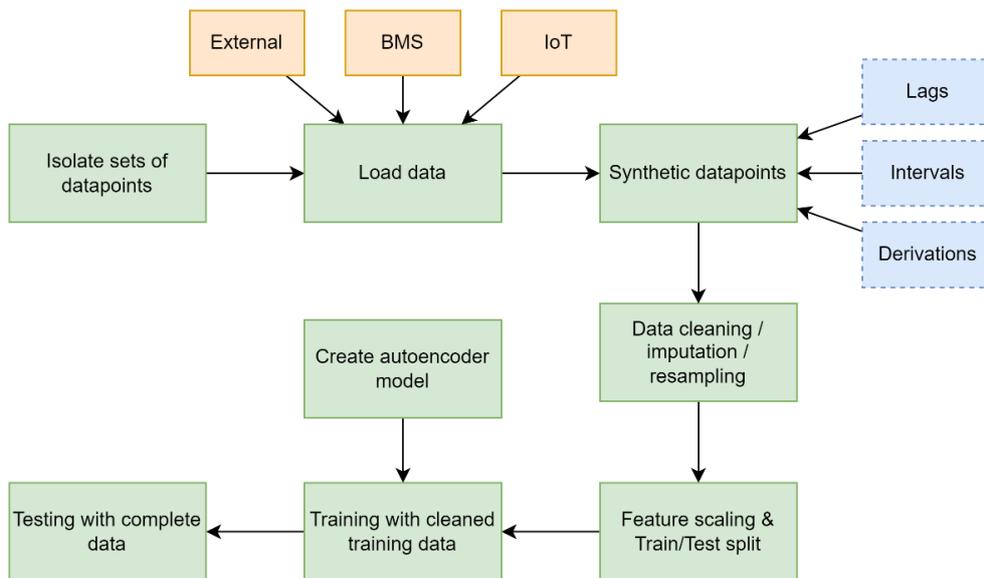
Bei der Anomalieerkennung werden Instanzen in Daten erkannt, welche deutlich von den meisten Dateninstanzen abweichen. (Pang et al. 2021b). Anomalien wirken sich negativ auf ein System aus, indem sie entweder dessen Betrieb stören bzw zur Gänze verhindern oder seine Effizienz verringern. Autoencoder sind häufig verwendete Methoden des maschinellen Lernens, die auf Aufgaben wie Komprimierung, Dimensionsreduktion und Anomalieerkennung angewendet werden. Einer der großen Vorteile bei der Anwendung von Autoencodern zur Erkennung von Fehlverhalten besteht darin, dass man diese komprimierten Repräsentationen mit Daten, welche keine Anomalien enthalten, trainieren kann.

Es wurden Datenpunkte aus verschiedenen Quellen (siehe UC1, UC2) kombiniert, welche auf den semantischen Verknüpfungen des BRICK-Modells basieren. Je nach Bedarf können unterschiedliche Verbindungen verwendet werden. Hierbei konzentrierte man sich auf System und Sub-Systemmodelle, sodass nur relevante Datenpunkte, welche einen Teil des zu untersuchenden Systems darstellen, zum Trainieren dieses Autoencoders verwendet wurden. Durch die Einrichtung einer Reihe von SPARQL-Abfragen und deren Anwendung auf das BRICK-Modell erhält man eine Reihe von Auflistungen jener Datenpunkte, welche dem dezidierten System angehören. Diese Datenpunktlisten werden mit zusätzlichen externen Datenpunkten wie Wetterdaten, Wettervorhersagen, Kalenderinformationen sowie synthetischen Datenpunkten angereichert. Synthetische Datenpunkte sind wiederum Datenpunkte, die einer Ableitung aus einem oder mehreren anderen Datenpunkten abgeleitet werden. Zu den hierfür verwendeten Methoden der Datenanalyse gehören Mittelung, Summierung, Bildung von Minima oder Maxima aus einer Auswahl von Datenpunkten für einen bestimmten Zeitraum.

Abbildung 8 zeigt den beschriebenen Arbeitsablauf der Datenverarbeitung und das Training des Anomaliedetektors. Im ersten Schritt werden relevante Datenpunkte, welche den Kontext eines Teilsystems des GAS (z.B. „O1HK\_V01“ eine Zone der Betonkernaktivierung) repräsentieren selektiert. Anschließend werden die hierfür benötigten Datensätze aus den unterschiedlichen internen und externen Quellen gesammelt. Da die Datenerfassung ereignisbasiert ist und neue Ereignisse in nicht deterministischen Intervallen eintreffen, ist es sinnvoll, für jeden ausgewählten Datenpunkt die Zeitintervalle seit dem letzten Ereignis zu berechnen. Dadurch könnte der Anomaliedetektor auch Probleme bei der Datenerfassung selbst erkennen (z. B. keine Daten vom Sensor in den letzten zwei Tagen). Als nächster Schritt erfolgt die Datenbereinigung von momentanen minimalen, maximalen oder Standardwerten. Alle Datenpunkte mit geringen oder keinen Änderungen während des gesamten Datenerfassungszeitraums werden ignoriert.

Die Daten werden in unterschiedliche Sets aufgeteilt, um sie zu trainieren und zu validieren. 80 % des Datensatzes werden zum Trainieren des Modells und 20 % zum Testen verwendet. Skalierungsparameter zum Skalieren jeder Zeitreihe auf den Bereich [0,1] werden berechnet und auf den Trainings- und Testdatensatz angewendet, um zu verhindern, dass einer der Datenpunkte übermäßigen Einfluss auf den Trainingsprozess hat. Sobald die Daten vorbereitet sind, werden Autoencoder-Modelle erstellt und trainiert. Die resultierenden Anomaliedetektoren werden an einem vollständigen Datensatz getestet, die Ergebnisse werden gespeichert und zur Analyse aufbewahrt.

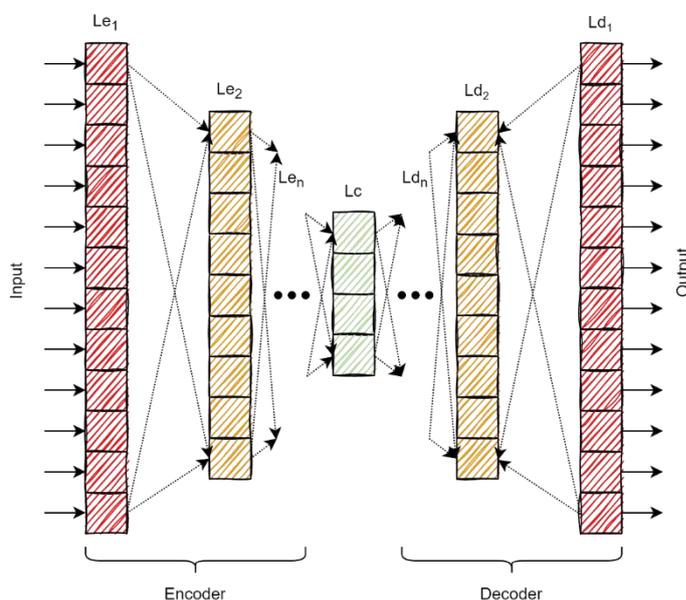
Abbildung 8: Arbeitsablauf der Datenverarbeitung und Anomaliedetektor-Training



Die Netzwerkarchitektur basiert auf dem klassischen symmetrischen Autoencoder-Konzept, wie in Abbildung 9 dargestellt. Eingehende Daten werden in das Netzwerk auf der Eingabeebene  $L_{e1}$  (Encoderebene 1) eingespeist. Die Größe der Eingabeebene entspricht der Anzahl der primären, externen und synthetischen Datenpunkte. Auf die Eingabeebene folgt eine n-1-Schichten tiefe Reihe dicht verbundener Schichten ( $L_{e2}$ - $L_{en}$ ), die mit einer codierten Darstellungsschicht ( $L_c$ ) endet. Darauf folgt eine Reihe von Decoderschichten ( $L_{dn}$ - $L_{d1}$ ), wobei die letzte die Ausgaben des Netzwerks liefert. Die Ausgaben stellen die Rekonstruktion der Eingaben des Autoencoders dar. Rectified linear unit wird als Aktivierungsfunktion für alle Schichten verwendet.

Alle Tensoren werden mit einer zufälligen Normalfunktion initialisiert, die Teil der Keras-Bibliothek (Chollet et al., 2015) ist, die eine high-level API zum Einrichten von Deep-Learning-Arbeitsabläufen bietet. Biases werden mit Nullen initialisiert.

Abbildung 9: Schematische Darstellung der symmetrischen Autoencoder-Architektur mit variabler Anzahl interner Schichten



Zur Optimierung wurde ein Hyperparameter-Tuning-Prozess eingerichtet, welcher nachfolgende Hyperparameter berücksichtigt: Anzahl der internen Schichten, Lernrate und Faktor für  $L_2$ -Regularisierung. Die Anzahl der internen Schichten war auf einen Satz [1, 3, 5, 7] (einschließlich der Codierungsschicht) beschränkt. Die Lernrate kann Werte aus dem Satz [0,01, 0,001, 0,0001] annehmen, während der  $L_2$ -Faktor aus dem Satz [0,01, 0,001, 0,0001] ausgewählt wird. Die Hyperparameter-Optimierung wird mit einem Hyperband-Tuner (Li et al., 2018) durchgeführt, einem Teil der Keras-Bibliothek.

Anomalien können als Punktanomalien oder Gruppen verwandter anomaler Messwerte auftreten. Es wurde das Konzept einer Anomaliegruppe eingeführt, bei der eine Gruppe einen oder mehrere anomale Punkte enthalten kann und jeder Anomaliepunkt innerhalb einer Gruppe nicht weiter als ein gewähltes Zeitdelta vom nächstgelegenen Anomaliepunkt innerhalb der Gruppe entfernt ist. Das Zeitdelta wurde mit 2 Stunden gewählt. Die Gruppierung ist besonders wichtig für Ansichten, die Benutzern zur Rückmeldung präsentiert werden sollen.

# 5 Ergebnisse

## 5.1. Modellvalidierung

### 5.1.1. Ergebnisse der Validierung – Use Case 1

In Use Case 1 resultierte die Datenaufbereitung in einem Trainingszeitraum von 19. März 2020 bis 26. Jänner 2023 und einem Validierungszeitraum von 27. Jänner 2023 bis 21. Dezember 2023 mit 4 Targets, 11 Zukunfts-Features und 23 Vergangenheits-Features. Tabelle 4 zeigt Ergebnisse für den Root Mean Square Error der verschiedenen untersuchten Machine Learning (ML)-Modelle. Es wird gezeigt, dass die Modelle für alle Modelltypen und Größen signifikant besser als das Baseline-Modell sind.

Tabelle 4: Root Mean Square Error (RMSE) der verschiedenen ML-Modelle in Use Case 1

Machine Learning Modell	RMSE Grundwasser- Volumenstrom	RMSE el. Leistung Wärmepumpe	RMSE el. Leistung Rückkühler	RMSE el. Leistung Regelung
Baseline	16,33	14,99	4,37	8,72
Lineare Regression	12,45	8,25	1,86	5,77
Light Gradient Boosting	10,65	7,63	1,26	3,80
Extreme Gradient Boosting	11,58	7,86	1,43	4,70

Abbildung 10 zeigt den wahren und den vorhergesagten Energieverbrauch des HLK-Systems für einen repräsentativen Abschnitt des Validierungszeitraums im Sommer 2023. Der Verbrauch ist hierbei die Summe der drei Leistungsgrößen unter den Targets. Die Vorhersage wurde durch das Light Gradient Boosting-Modell erstellt und setzt sich aus mehreren Einzelvorhersagen zusammen, die im Abstand von einem Tag getroffen wurden und jeweils einen Tag in die Zukunft reichten. Die Außentemperatur war das wichtigste Feature für die Vorhersage. Zu erkennen ist, dass die Vorhersage den wahren Verbräuchen recht gut folgt, sie aber nahezu durchgehend leicht überschätzt, vor allem an heißen Tagen.

Abbildung 11 zeigt den wahren und den optimierten vorhergesagten Energieverbrauch des HLK-Systems für einen ausgewählten Tag im Zeitraum August 2023. Für diesen Tag ist die optimierte und den Grundwasserentnahmeauflagen entsprechende Vorhersage vergleichbar mit dem wahren Verbrauch. Ebenso sind in diesem Fall die Werte der Regelgrößen dieselben. Zum Vergleich zeigt die Abbildung die optimierte Vorhersage *ohne* Berücksichtigung der Grundwasserentnahmeauflagen, die deutlich niedriger liegt.

Abbildung 10: Wahrer und vorhergesagter Energieverbrauch des HLK-Systems sowie die Außen-temperatur für einen repräsentativen Zeitraum im Sommer 2023

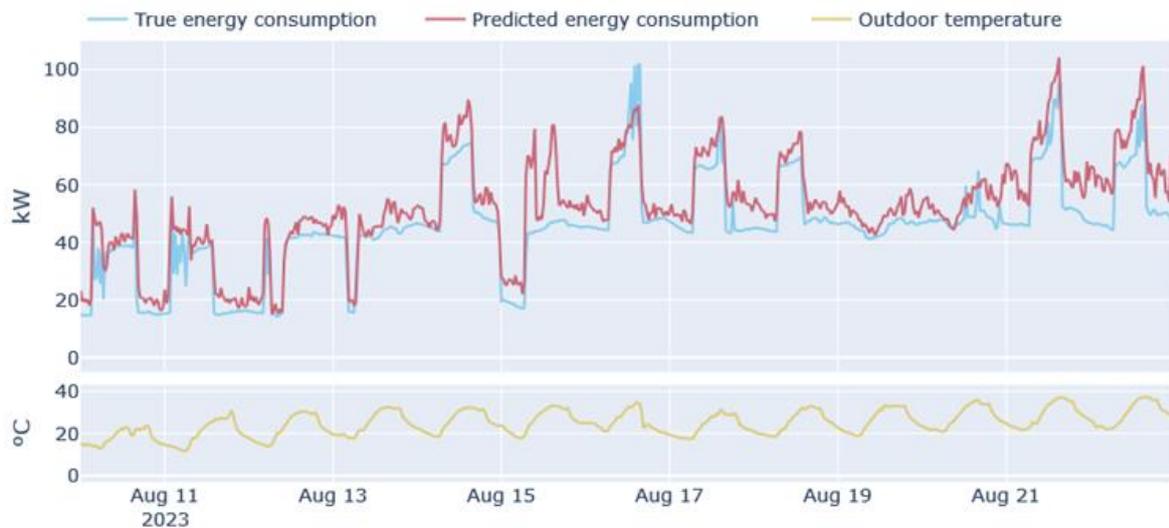
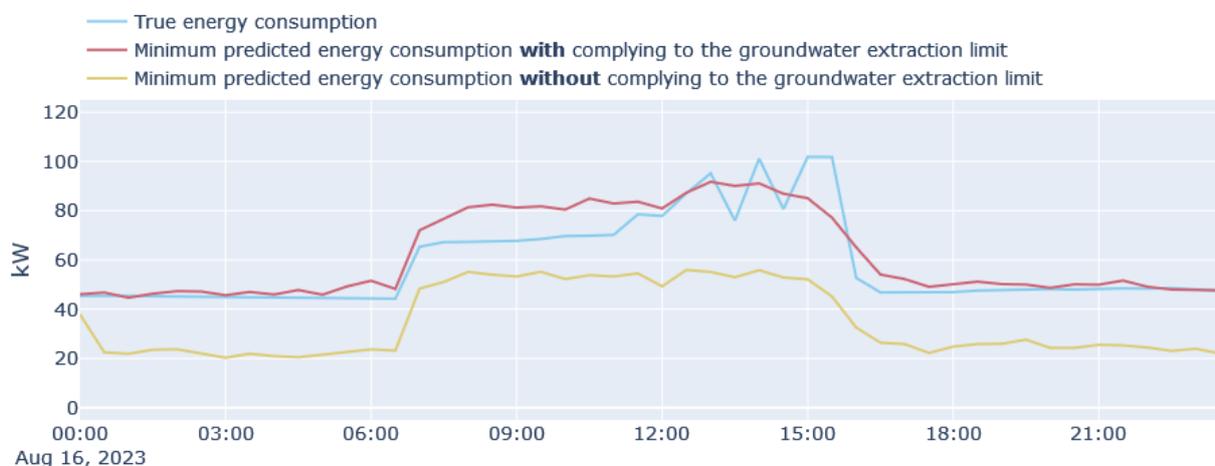


Abbildung 11: Wahrer und optimierter vorhergesagter Energieverbrauch des HLK-Systems für einen ausgewählten Tag im Sommer 2023



### 5.1.2. Ergebnisse der Validierung – Use Case 2

Zur Beschleunigung der Entwicklung von Use Case 2 nach der Datenaufbereitung wurde das Zeitraster von 15min auf 2h gestreckt sowie zunächst nur der Raum 1.107 betrachtet. Die hier besprochenen Ergebnisse beziehen sich auf diese Vereinfachungen und einen Datenzeitraum bis März 2024. In der Operationalisierung des Anwendungsfalls wurden anschließend mehr verschiedene Räume sowie Daten aus einem etwas längeren Zeitraum verarbeitet.

Für den betrachteten Raum 1.107 resultierte die Datenaufbereitung in einem Trainingszeitraum von 8. September 2022 bis 22. März 2023 und einem Validierungszeitraum von 23. März 2023 bis 16. August 2023. Die Menge nutzbarer Daten war hierbei vor allem durch die Verfügbarkeit der IoT-Daten begrenzt und umfasste 3 Targets, 23 Zukunfts-Features und 30 Vergangenheits-Features. Tabelle 5 zeigt Ergebnisse für den Root Mean Square Error des Light Gradient Boosting-Modells für den betrachteten Raum.

Hierbei ist zu erkennen, dass die Vorhersage nur wenig besser ist als diejenige des Baseline-Modells.

Tabelle 5: Root Mean Square Error (RMSE) der ML-Modelle für den betrachteten Raum 1.107

Machine Learning Modell	RMSE	RMSE	RMSE
	Raumtemperatur	Luftfeuchtigkeit	Betonkerntemperatur
Baseline	0,97	7,35	0,80
Light Gradient Boosting	0,83	7,25	0,84

Abbildung 12 zeigt die wahre und vorhergesagte Raumtemperatur und -luftfeuchtigkeit für einen Teil des Validierungszeitraums im Sommer 2023. Die Vorhersage setzt sich aus mehreren Drei-Tages-Vorhersagen zusammen, die im Abstand von drei Tagen getroffen wurden. Die Außentemperatur und -luftfeuchtigkeit stellten die wichtigsten Prädiktoren für die Vorhersage dar. Zu erkennen ist, dass die Temperaturvorhersage einigermaßen genau dem wahren Verlauf folgt, während dies für die Luftfeuchtigkeit weniger der Fall ist.

Abbildung 12: Wahre und vorhergesagte Raumtemperatur und -luftfeuchtigkeit im betrachteten Raum 1.107 für einen Zeitraum im Sommer 2023

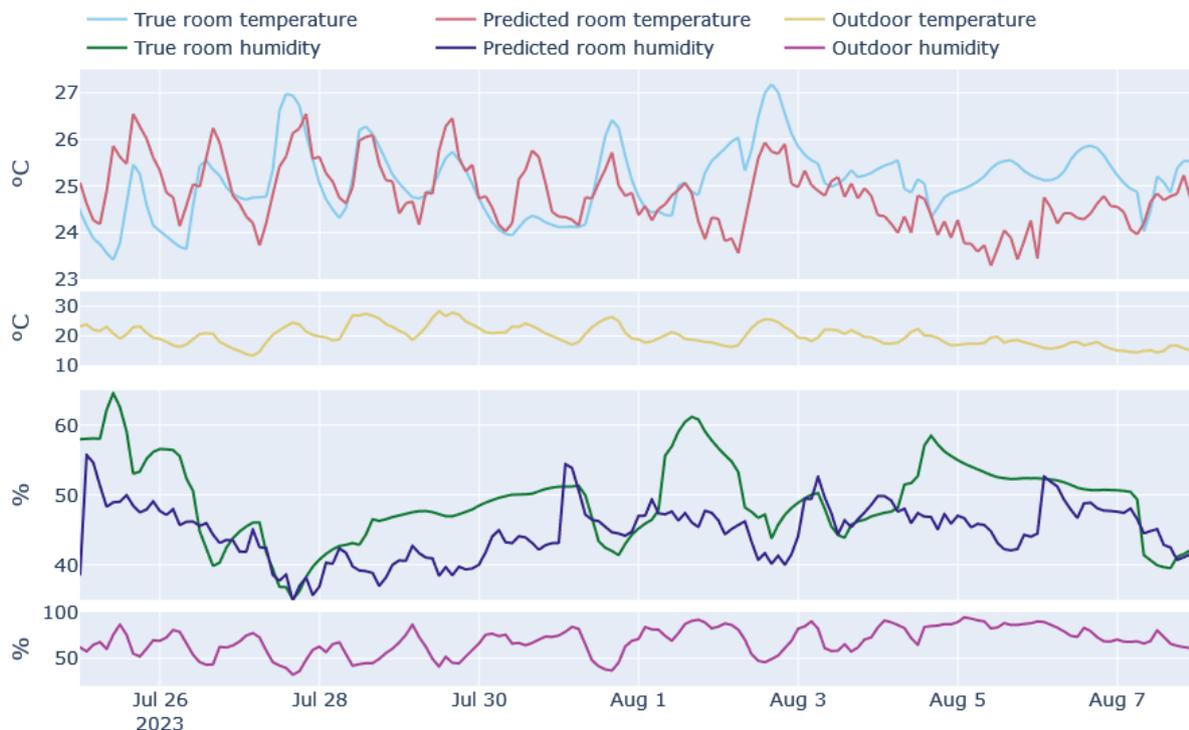
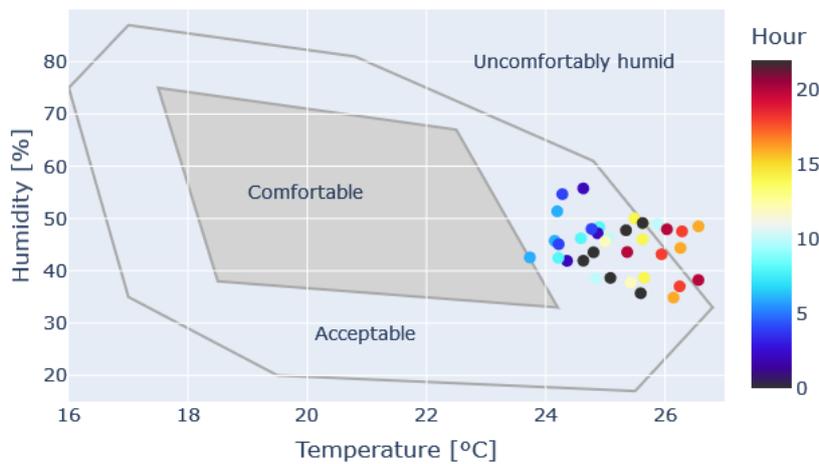


Abbildung 13 zeigt eine Drei-Tages-Vorhersage in Form eines Behaglichkeitsdiagramms. Im Diagramm ist der Zeitraum von 2023-07-25 bis 2023-07-27 abgebildet, welcher in Abbildung 12 enthalten ist. Jeder der farbigen Punkte repräsentiert einen der 72h/2h=36 Zeitpunkte im Vorhersagezeitraum.

Abbildung 13: Behaglichkeitsdiagramm mit der Raumtemperatur- & -luftfeuchtigkeitsvorhersage im betrachteten Raum 1.107 für einen Drei-Tages-Zeitraum im Sommer 2023. Die farbigen Punkte repräsentieren 36 verschiedene Zeitpunkte in diesem Zeitraum.



### 5.1.3. Ergebnisse der Validierung – Use Case 3

Tabelle 6 zeigt die besten Rekonstruktionsfehler und die jeweiligen Modell-Hyperparameter für jede verwendete System- und Verzögerungskombination. Interessanterweise haben alle ausgewählten Modelle nur eine interne Schicht, nämlich die Kodierungsschicht. Bei Modellen mit kleineren Eingabegrößen (O1HK\_V01 und O1HK\_V02) wurde ein L2-Faktor von 0,001 ausgewählt. Bei allen anderen Modellen lieferte ein L2-Faktor von 0,0001 die besten Ergebnisse. Eine größere Lernrate von 0,01 scheint von Modellen mit kleineren Kodierungsgrößen bevorzugt zu werden, wobei größere Kodierungsgrößen kleinere Lernraten von 0,001 begünstigen. Die Erkenntnisse aus der Optimierung des Hyperparameterraums werden bei weiteren Untersuchungen verwendet.

Tabelle 6: Rekonstruktionsfehlerschwelle und Eigenschaften der besten Modelle jeder Kategorie (System, Verzögerungen)

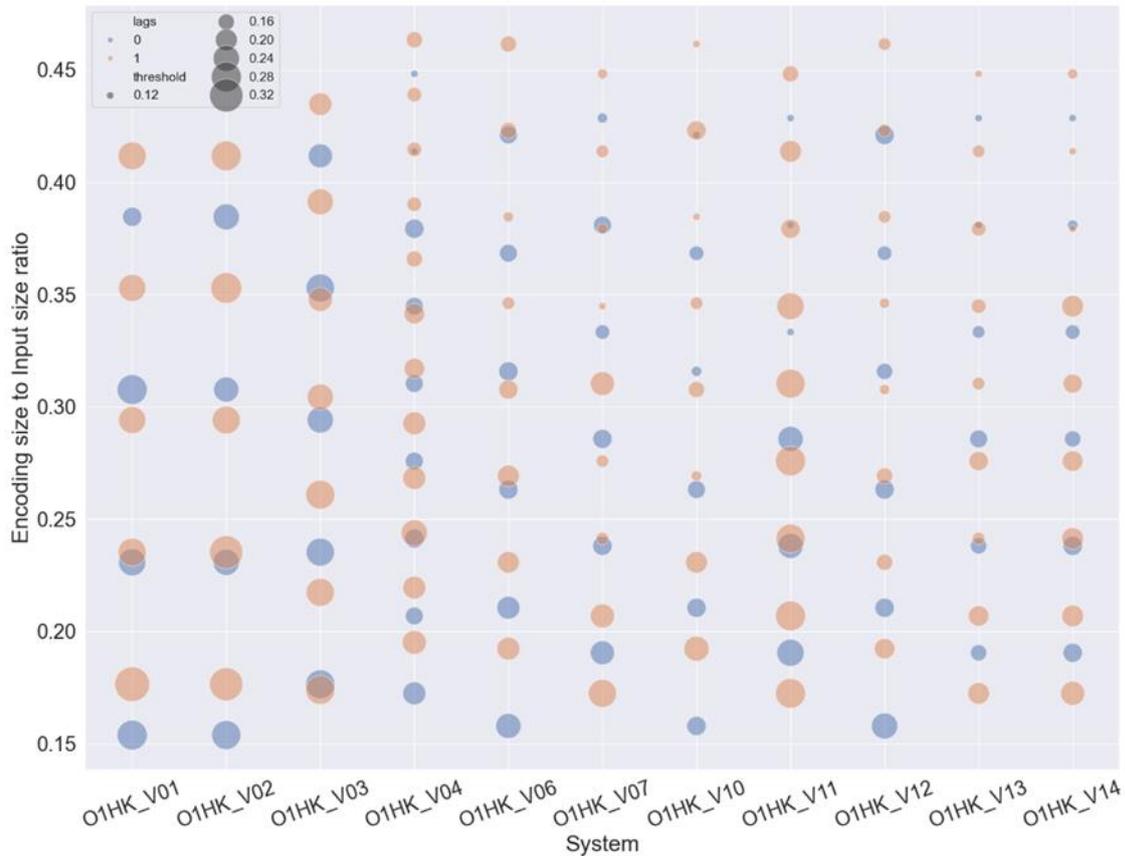
System	Lags	Input Größe	Encoding Größe	interne Schichten	Lernrate	L2 Faktor	Schwelle
O1HK_V01	0	13	5	1	0.01	0.001	0.18
O1HK_V01	1	17	5	1	0.01	0.001	0.25
O1HK_V02	0	13	4	1	0.01	0.001	0.23
O1HK_V02	1	17	5	1	0.01	0.001	0.26
O1HK_V03	0	17	7	1	0.01	0.0001	0.22
O1HK_V03	1	23	10	1	0.01	0.0001	0.21
O1HK_V04	0	29	12	1	0.001	0.0001	0.12
O1HK_V04	1	41	16	1	0.001	0.0001	0.15

System	Lags	Input Größe	Encoding Größe	interne Schichten	Lernrate	L2 Faktor	Schwelle
O1HK_V06	0	19	7	1	0.01	0.0001	0.17
O1HK_V06	1	26	10	1	0.01	0.0001	0.13
O1HK_V07	0	21	9	1	0.001	0.0001	0.13
O1HK_V07	1	29	10	1	0.01	0.0001	0.12
O1HK_V10	0	19	8	1	0.001	0.0001	0.12
O1HK_V10	1	26	10	1	0.01	0.0001	0.12
O1HK_V11	0	21	7	1	0.001	0.0001	0.12
O1HK_V11	1	29	13	1	0.001	0.0001	0.16
O1HK_V12	0	19	7	1	0.001	0.0001	0.15
O1HK_V12	1	26	8	1	0.001	0.0001	0.13
O1HK_V13	0	21	8	1	0.001	0.0001	0.12
O1HK_V13	1	29	13	1	0.001	0.0001	0.12
O1HK_V14	0	21	9	1	0.001	0.0001	0.12
O1HK_V14	1	29	11	1	0.001	0.0001	0.12

Die Kodierungsdimension ist der wichtigste Modellparameter und beeinflusst die Datenrekonstruktionsfähigkeit des Modells. Der Schwellenwert aus der Tabelle wird als mittlerer Rekonstruktionsfehler berechnet, was zu 10 Gruppen von Anomalien führt.

In mehr als der Hälfte der Beispiele (14 von 22) wurde der beste Rekonstruktionschwellenwert vom Modell mit der größten Kodierungsschicht erwartungsgemäß nicht erreicht. Wir haben das Verhältnis von Kodierungsgröße zu Eingabegröße berechnet und die Schwellenwerte aller trainierten Modelle in Abbildung 14 dargestellt. Auf der x-Achse sind verschiedene Systeme dargestellt. Kreisgrößen geben Schwellenwerte an (kleiner ist besser), während die Farbe angibt, ob der jeweilige Modelleingang Datenpunktverzögerungen enthält. Der obere Teil des Diagramms (Verhältnis von Kodierung zu Eingabe ist höher) stellt Modelle mit lockererer Komprimierung und erwarteter besserer Rekonstruktion dar, während der untere Teil des Diagramms Modelle mit eingeschränkterer Darstellung und folglich schlechterer Rekonstruktion zeigt.

Abbildung 14: Rekonstruktionsfehlerschwellenwerte



## 5.2. Evaluierung

Darstellung der Einpassung in das Förderprogramm siehe Kommentar „Ergebnisse“

### 5.2.1. Ergebnisse der Evaluierung – Use Case 2

Der Zweck der funktionellen Evaluierungsstudie zur thermischen Behaglichkeit ist es, die Verbesserung der thermischen Behaglichkeit zu testen, die aus der Aktivierung der Temperatur der Betonschlange resultiert. Die Studie wurde über einen Zeitraum von sechs Wochen in dem AIT-Gebäude FUTUREbase durchgeführt.

Vor der Durchführung der Untersuchung wurden die MitarbeiterInnen der Büros in dem FUTUREbase-Gebäude über das Ziel der Evaluierungsphase informiert. Der Infotag wurde am 9. April 2024 am AIT in Kooperation mit PKE organisiert, zu dem alle MitarbeiterInnen des Center for Vision, Automation & Control eingeladen waren. Während des Meetings wurden die MitarbeiterInnen über die Auswertung der Messungen der thermischen Behaglichkeit informiert, die im Sommer 2022 und im Winter 2023 durchgeführt wurden. Aufgrund der südlichen Ausrichtung und der hohen Belegung wurde das Büro 1.107 als das kritischste identifiziert. Daher wurde vereinbart, die Tests der Evaluierungsphase in allen Büros vom FUTUREbase-Gebäude durchzuführen, aber speziell die Daten im Büro 1.107 zu messen.

Insgesamt wurden die Messungen des thermischen Komforts über einen Zeitraum von sechs Wochen durchgeführt. In den ersten drei Wochen wurde das Büro 1.107 hinsichtlich der Temperatur und der relativen Feuchtigkeitsverhältnisse charakterisiert. Auf Grundlage der erfassten Daten und der

Wetterdaten für die kommenden Wochen wurden danach die Prognosen zur thermischen Behaglichkeit erstellt und eine zweite Messserie über drei Wochen durchgeführt. Der Messplan ist in Tabelle 7 dargestellt.

Tabelle 7: Messplan für die Evaluierung der thermischen Behaglichkeit

Beschreibung der Messung	Beginn am	Endet am	Evaluierungstage
Büroklimacharakterisierung	Mittwoch, den 24. April	Dienstag, den 30. April	-
Büroklimacharakterisierung	Mittwoch, den 1. Mai	Dienstag, den 7. Mai	-
Büroklimacharakterisierung	Mittwoch, den 15. Mai	Dienstag, den 21. Mai	-
Büroklimacharakterisierung nach Aktivierung der Betontemperatur	Montag, den 27. Mai	Freitag, den 31. Mai	Montag, den 27. Mai
Büroklimacharakterisierung nach Aktivierung der Betontemperatur	Montag, den 17. Juni	Freitag, den 21. Juni	Montag, den 17. Juni
			Mittwoch, den 19. Juni
Büroklimacharakterisierung nach Aktivierung der Betontemperatur	Montag, den 24. Juni	Freitag, den 28. Juni	Montag, den 24. Juni
			Mittwoch, den 26. Juni

Für den Zweck dieses Berichts werden zwei Beispielwochen ausgewählt, um die Charakterisierung des Innenklimas für das Büro 1.107 darzustellen. In der ersten Woche wird eine Büroklimabewertung durchgeführt, ohne die Aktivierung des Betonkerns. Die zweite Woche zeigt stattdessen die Ergebnisse der Büroklimabewertung nach den Änderungen der Betonkerntemperatur und unter Berücksichtigung der im Laufe der Woche durchgeführten Vorhersagen.

Abbildung 15: Büroklimacharakterisierung ohne Aktivierung der Betonkerntemperatur

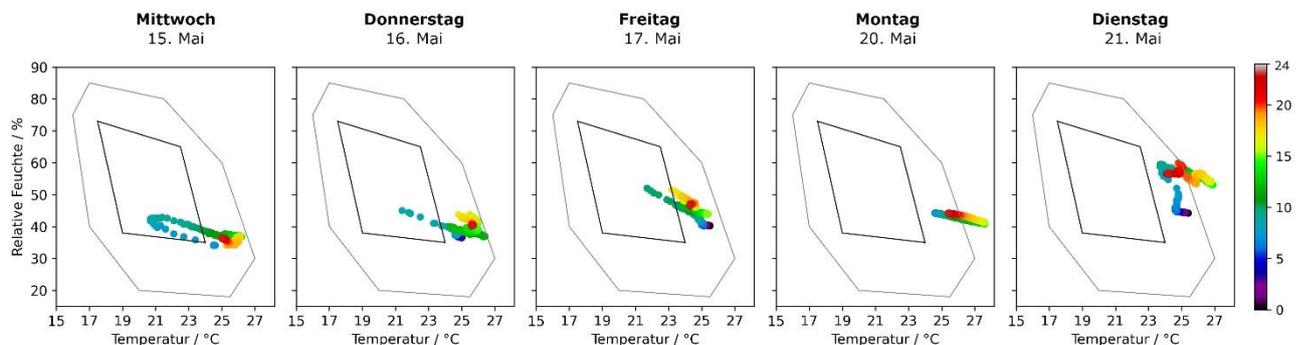
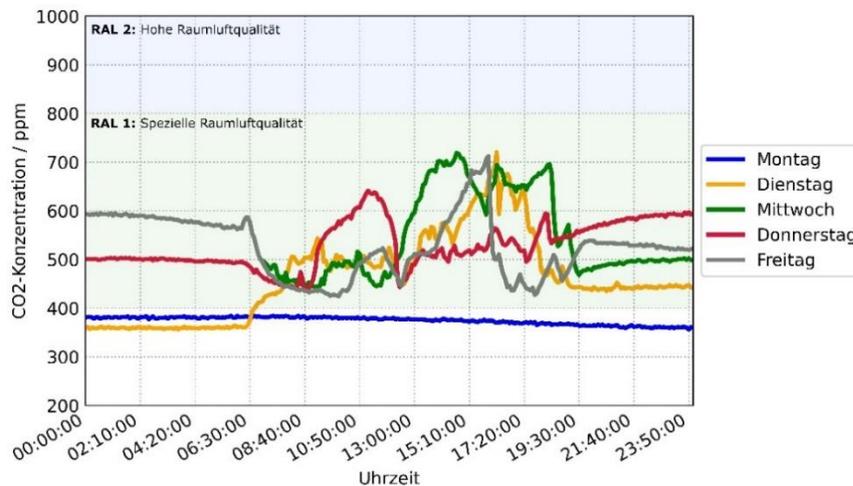


Abbildung 16: CO<sub>2</sub>-Konzentration

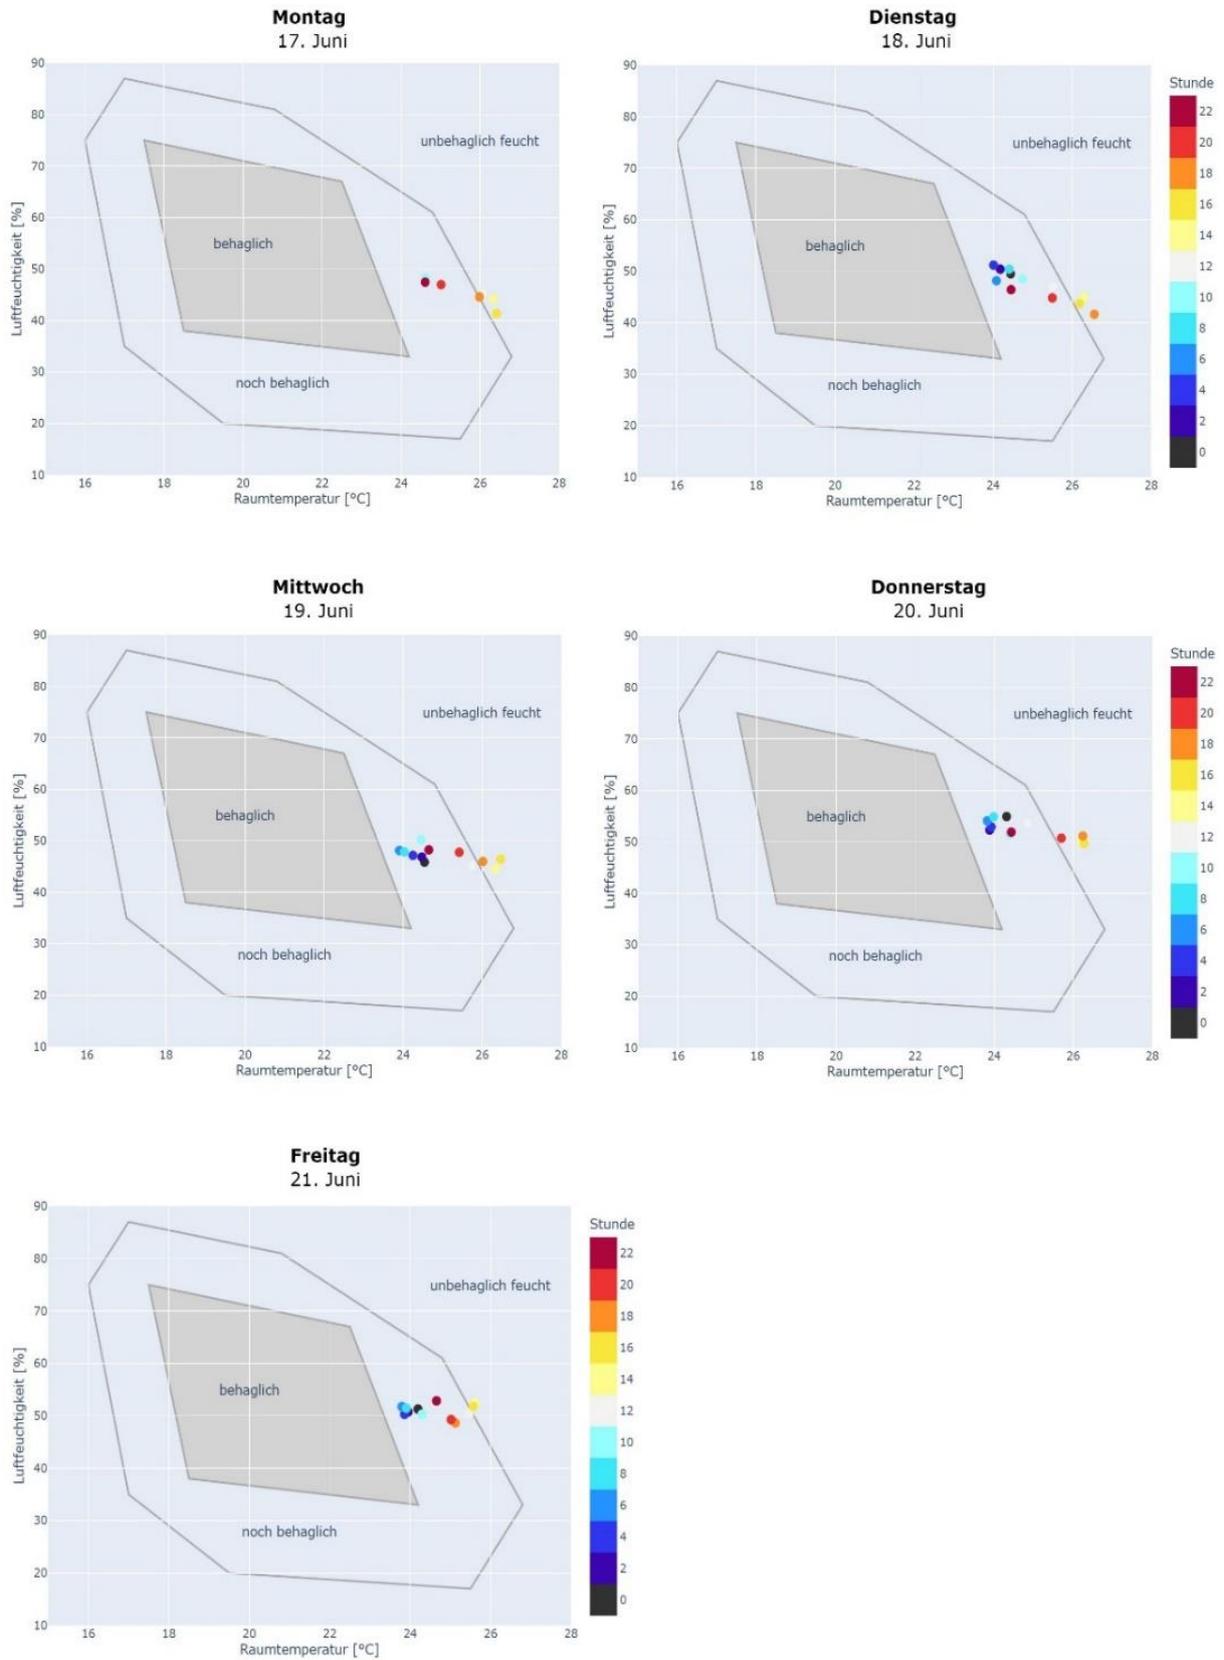


Laut den Ergebnissen für die Woche zwischen dem 15. Mai und dem 21. Mai konnten die folgenden Erkenntnisse für das Raumklima im Büro 1.107 gezogen werden:

- Die internen Lasten im Büro, die aufgrund der hohen Belegung und der intensiven Nutzung des Computers für Simulationsaktivitäten resultieren, führen zu hohen Temperaturen während des Tages, die den thermischen Komfort verringern.
- Die optimalen Werte für die thermische Behaglichkeit sind fast nie erreicht, aber in den meisten Fällen liegen die relative Luftfeuchtigkeit und die Lufttemperatur im Bereich von "noch behaglich" laut dem Behaglichkeitsdiagramm von Frank.
- Der Höchstwert der Lufttemperatur wird normalerweise zwischen 15 und 16 Uhr erreicht.
- Entsprechend den Ergebnissen, die über alle Messwochen gesammelt wurden, sind Dienstag, Mittwoch und Donnerstag die am meisten belegten Tage.
- Die Luftqualität im Büro entspricht in den meisten Fällen der Kategorie RAL 1 gemäß der Norm DIN EN 13779. Die hohe Belegung führt zu Spitzen in der CO<sub>2</sub>-Konzentration. Daher ist eine Belüftung des Raumes erforderlich. Laut den Messungen wird dies normalerweise von den Mitarbeitern getan, obwohl die Konzentration nie den unteren Grenzwert von 400 ppm erreicht, außer wenn das Büro leer ist.

Ein Beispiel für eine Woche, in der die Betonkernaktivierung auf der Grundlage der Vorhersage der thermischen Behaglichkeit einbezogen wird, wird im Folgenden dargestellt. Der Workflow für die Ermittlung der neuen Solltemperatur für den Betonkern beginnt am Montagvormittag gegen 7 Uhr. Der erste Schritt ist die Data-Fetching für die Temperatur und die relative Luftfeuchtigkeit der vorherigen Woche in allen untersuchten Büros. Sobald der Datensatz verfügbar ist, werden die Vorhersagen unter Berücksichtigung der prognostizierten Wetterdaten für die gesamte Woche durchgeführt. Sobald die Vorhersagen fertig sind, werden die Daten analysiert und der neue Sollwert für den Betonkern wird festgelegt. Allerdings ist ca. ein Tag erforderlich, um die Betonkerntemperatur vollständig zu aktivieren. Aus diesem Grund wird die Temperaturentwicklung der Betonkern bis Dienstag überwacht. Die Bewertung ist sowohl am Montag als auch am Mittwoch erfolgt. Der Grund für die zweite Auswertung am Mittwoch ist die Verbesserung der Vorhersage der thermischen Behaglichkeit. Dazu wird derselbe Workflow wie am Montag wiederholt, aber dieses Mal werden die Daten vom Wochenanfang (Montag und Dienstag) verwendet, um genauere Ergebnisse zu erhalten.

Abbildung 17: Vorhersagen zum thermischen Komfort vom 17. bis 21. Juni



Wie die Prognosen für die zweite Junihälfte zeigen, beeinflusst die höhere Außenlufttemperatur das Raumklima und führt zu allgemein höheren Werten für die Temperatur im Büro, die zwischen 14 und 18 Uhr meist in den Bereich "unbehaglich" fällt. Die relative Luftfeuchtigkeit wurde immer zwischen 40 und 56 % vorhergesagt, was bei niedrigeren Temperaturen ein gutes Intervall für die thermische Behaglichkeit ist. Daher ist auch in diesem Fall die Temperaturreduzierung der wichtigste Parameter für die Verbesserung des Raumklimas.

Tabelle 8: Betonkerntemperatur Aktivierung zwischen dem 17. und 21. Juni

		Anfangstemperatur / °C	Neue Einstellungen / °C	Endgültige Temperatur am folgenden Tag / °C
<b>Evaluierungstag:</b> Montag, den 17. Juni	<b>Betonkern 1</b>	Berechnet: 20 Gemessen: 21,5	Raumeinflussfaktoren Wärmegrenze: 0 Kühlgrenze: -5	Berechnet: 19 Gemessen: 21,5
	<b>Betonkern 2</b>	Gemessen: 19,7		Gemessen: 19,5
<b>Evaluierungstag:</b> Mittwoch, den 19. Juni	<b>Betonkern 1</b>	Berechnet: 19 Gemessen: 21,5	Sollwert: 20,5	Berechnet: 14,7 Gemessen: 20,9
	<b>Betonkern 2</b>	Gemessen: 19,5		Gemessen: 19,5

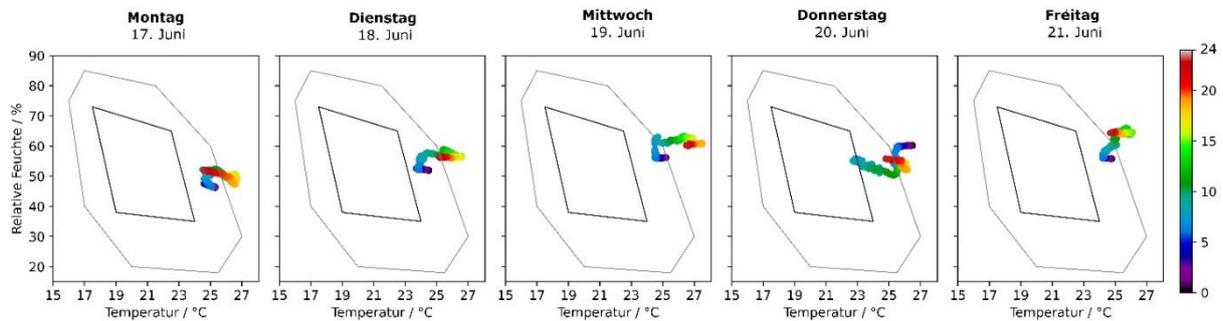
Am Montag wurde die Temperatur der Betonspule reduziert, wobei die Raumeinflussfaktoren bis zum Extremwert von (0, -3) auf (0, -5) eingestellt wurden. Dies entspricht einer Verringerung der berechneten Betontemperatur um 1 K, von 20 auf 19 °C. Trotz der von der Softwareschnittstelle erwarteten Änderung wurde am nächsten Tag immer noch eine Temperatur von 21,5 °C für die Betonspule gemessen. Dafür kämen zwei Hypothesen in Frage:

- Die extrem hohen Wärmegewinne aus dem Büro 107 in Verbindung mit der höheren Außentemperatur spielten der Reduzierung der Betontemperatur entgegen.
- Die Temperatur in den anderen südlich ausgerichteten Büros des FUTUREbase-Gebäudes wurde von den MitarbeiterInnen als zu niedrig empfunden. Daher könnten sie das Fenster geöffnet und die Innentemperatur des Raumes erhöht haben.

Am zweiten Evaluierungstag wurde der Sollwert nochmals angepasst. Diesmal wurde der Temperatursollwert um 1 K von 21,5 auf 20,5 °C gesenkt, da die Raumeinflussfaktoren bereits an ihren Grenzen eingestellt waren. Die Kombination des neuen Temperatursollwerts mit den Raumeinflussfaktoren ist zu einer berechneten Betonkerntemperatur von 14,7 °C resultiert. Dieser extrem niedrige Wert ist für das System jedoch unrealistisch, da er zu Kondensationsproblemen führen würde. Deshalb hat das System diese Reduzierung nicht erlaubt, wie es erwartet wurde. Dennoch wurde diese neue Einstellung ausprobiert, um die minimale Temperatur der Betonschlange zu testen, die während des Betriebs des Systems möglich war. Es wurde herausgefunden, dass diese Temperatur am Tag nach der Einstellung des neuen Sollwerts bei etwa 20,9 °C liegt.

Trotz der sehr niedrigen Temperatur der Betonschlange wurde keine Verbesserung des thermischen Komforts festgestellt. Im Gegenteil, es stellte sich heraus, dass diese schlechter war als der prognostizierte Trend (siehe Abbildung 18).

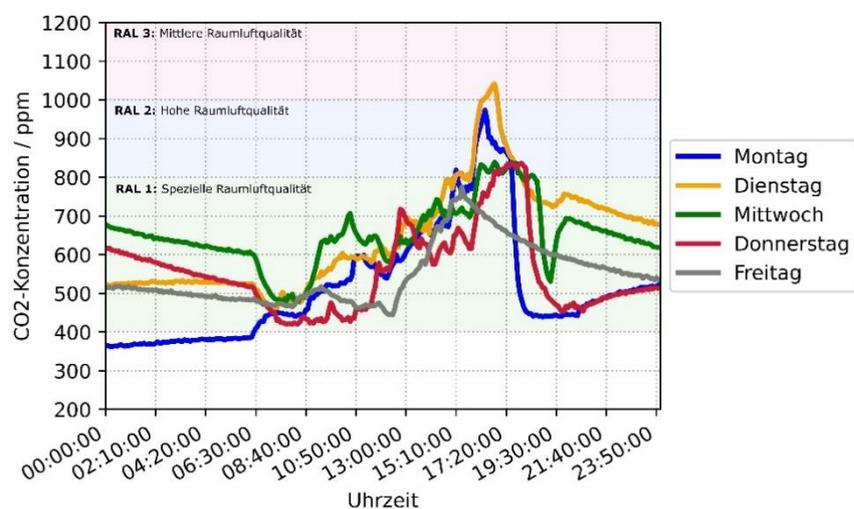
Abbildung 18: Büroklimacharakterisierung nach der Betonkernaktivierung vom 17. bis 21. Juni



Der kritischste Tag war der Mittwoch, an dem alle Messwerte während der Arbeitszeit außerhalb des Komfortbereichs lagen und eine Spitzentemperatur von 27,5 °C erreicht wurde. Die einzige Möglichkeit, dies zu erklären, besteht darin, dass das Verhalten der Büromitarbeiter in der Prognose nicht korrekt berücksichtigt wurde und gegen die neuen Sollwerte für die Betonspule gespielt hat. Ein Beispiel dafür könnte sein, dass sie, z.B. die Fenster geöffnet haben, um den Raum zu belüften.

Was eindeutig gesagt werden kann, ist, dass die Belegung des Büros an diesen Tagen sehr hoch war, mit Spitzenwerten von über 950 ppm am Montag und Dienstag.

Abbildung 19: CO<sub>2</sub>-Konzentration vom 17. bis 21. Juni



Zusammenfassend kann festgestellt werden, dass:

- Die Vorhersagen zur thermischen Behaglichkeit sind erfolgreich verlaufen, da sie das Raumklima im Raum für die untersuchten Wochen ziemlich genau widerspiegeln.
- Die Genauigkeit der Vorhersagen könnte verbessert werden, wenn die Prognosen mehrmals pro Woche durchgeführt würden.
- Die Durchführung von Vorhersagen zur thermischen Behaglichkeit könnte dazu beitragen, das Raumklima im Büro zu verbessern, doch aufgrund der hohen internen Gewinne des Büros 1.107 reicht dies nicht aus, um optimale thermische Komfortbedingungen zu erreichen.

- Der Betonkern wird normalerweise erst ca. einen Tag nach Einstellung der neuen Sollwerte voll aktiviert. Die relativ langsame Umsetzung der Betonkerntemperatur führt dazu, dass er nicht zur Abdeckung von Spitzenlasten, sondern von Grundlasten geeignet ist.

### 5.2.2. Ergebnisse der Evaluierung – Use Case 3

Im Rahmen des Projekts mAMaintenance wurde eine umfassende Anomaliendetektion der Energiedaten der Future Base durchgeführt. Dieser Prozess bildete eine zentrale Komponente des Projekts, da die Analyse und das Verständnis von Anomalien in den Energiedaten von entscheidender Bedeutung für die Optimierung des Energieverbrauchs und die Identifizierung potenzieller betrieblicher Probleme sind. Zur Unterstützung dieser komplexen Aufgabe kam die spezialisierte Software aedifion zum Einsatz, die fortschrittliche Funktionen zur Visualisierung und Analyse der erfassten Daten bietet.

Insgesamt wurden über 150 Anomaliegruppen analysiert und dokumentiert. Eine Vielzahl der detektierten Anomalien wurde nicht detailliert untersucht oder dokumentiert, da sie offensichtlich keine realen Anomalien darstellten. Mehr als 50 der dokumentierten Anomalien waren falsch-positive Erkennungen, die dennoch eingehend analysiert wurden, um als Grundlage zur Verbesserung der Detektionsgenauigkeit zu dienen. In unserer Analyse wurden etwas mehr als 90 der detektierten Anomalien als tatsächliche Anomalien bestätigt. Um einen Überblick über die Klassifizierung und typische Anomalieverläufe zu geben, können folgende Typen zusammengefasst werden:

Tabelle 9 - Anomalienklassifizierung

<b>anomaly classification</b>
datadriven
abnormal valve behavior
temperature peak

Die Klasse „datadriven“ beschreibt jede Anomalie bei der entweder Messdaten fehlen oder fehlerhaft gespeichert wurden. Bei „abnormal valve behavior“ ist die Ursache der Erkennung meist auf rapider Wechsel der Heiz- und Kühlventile, zu schnelles Öffnen oder seltene gleichzeitige Öffnung beider Ventile zurückzuführen. Die Klasse „temperature peak“ beschreibt Anomalien bei denen die Raumtemperatur zu hoch wird, sich sprunghaft ändert oder durch Fensteröffnungen deutlich verändert wird.

#### **Kurzzeitige Spitzen**

Wie in Abbildung 20 erkennbar sind kurzzeitige Änderungen mit hoher Differenz der Werte von Messdaten als Spitzen in der Anomaliendetektion erkennbar. In diesen Fällen wurden über einen längeren Zeitraum von ca. 24h bis mehreren Tagen vor der Anomalie keine Messdaten aufgezeichnet. Diese erkennbare Spitze kommt häufig vor und wird als Anomalie der Klasse „datadriven“ mit niedriger Relevanz festgehalten.

Diff



Abbildung 20 – Anomalientyp: Kurzzeitige Spitzen

### Flache Linien

Wie in Abbildung 21 erkennbar sind Anomalien mit flachen Linien meist auf fehlende Daten oder nur sehr geringen Änderungen der Messdaten zurückzuführen. Oft sind dabei Datenpunkte von Sensoren komplett ausgefallen oder haben weiterhin den letztgemessenen Wert an die GLT übergeben. Diese flachen Linien kommen häufig vor und werden als Anomalie der Klasse „datadriven“ mit niedriger Relevanz festgehalten.

System: O1HK\_V01    Model: lag\_0\_encodingsize\_3\_learning    0.25000000000000001    Anomaly gr... 2

Diff

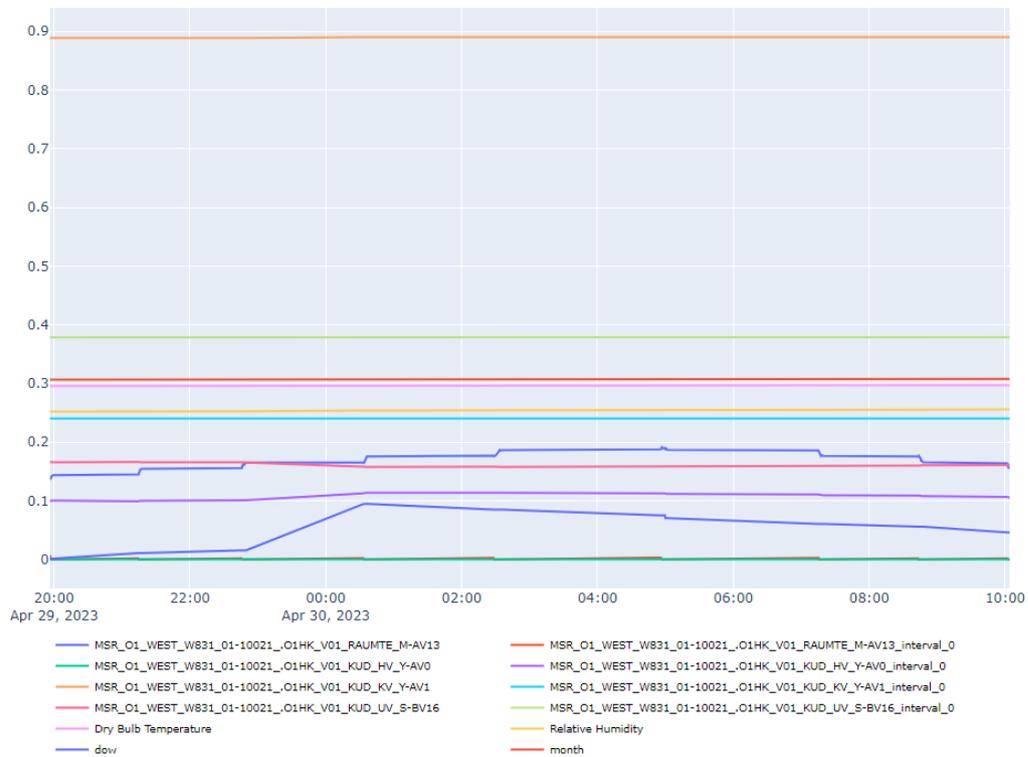


Abbildung 21 - Anomalientyp: Flache Linien

### Schnelle Änderungen

Wie in Abbildung 22 erkennbar sind Anomalien bei denen viele Änderungen gleichzeitig passieren auf Ventilstellgradänderungen zurückzuführen. In diesem Beispiel sind die Heiz- und Kühlventile mehrfach und schnell ein- und ausgeschaltet worden, wobei die Raumtemperatur konstant bleibt. Diese schnellen Änderungen kommen selten vor und werden als Anomalie der Klasse „abnormal valve behavior“ mit niedriger Relevanz festgehalten.

Diff



Abbildung 22 - Anomalientyp: Schnelle Änderungen

### Temperaturspitzen

Wie in Abbildung 23 erkennbar sind Anomalien bei denen hohe Bögen erkennbar sind auf erhöhte Temperaturspitzen zurückzuführen. In diesem Beispiel ist die Temperatur auf bis zu über 27°C aufgeheizt worden. Hierbei handelt es sich um einen Fehler in der Regelung. Diese Spitzen kommen selten vor und werden als Anomalie der Klasse „temperature peak“ mit höherer Relevanz festgehalten.

Diff

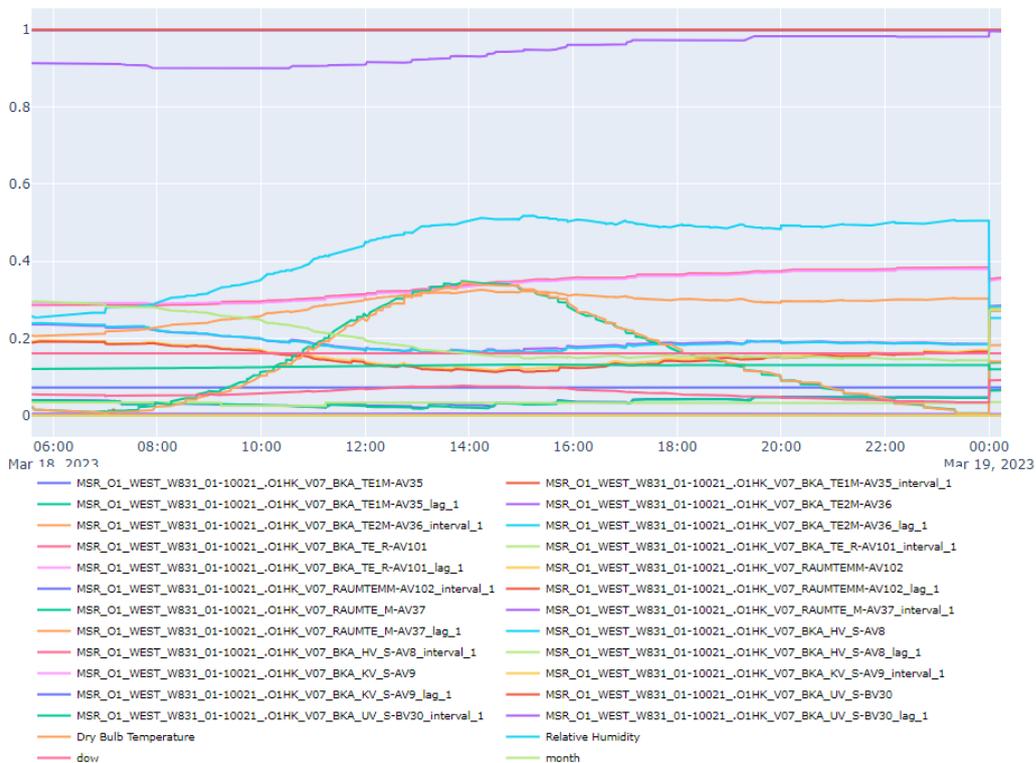


Abbildung 23 - Anomalientyp: Temperaturspitzen

Die Anomaliedetektion hat erfolgreich aufgezeigt, dass die Mehrzahl der identifizierten Anomalien auf einfache Datenfehler zurückzuführen ist. Durch den Einsatz von KI-Algorithmen konnten diese Anomalien sichtbar gemacht und anschließend analysiert werden. Dies ermöglicht eine präzisere und effizientere Nutzung der vorhandenen Ressourcen, indem der Fokus auf tatsächliche Abweichungen gelenkt wird. Diese proaktive Herangehensweise trägt zur Optimierung des Energieverbrauchs bei und ermöglicht die rechtzeitige Identifikation und Behebung potenzieller betrieblicher Probleme.

Die Anomaliedetektion bietet wertvolle Einblicke in potenzielle Energieeinsparungen im laufenden Betrieb. Beispielsweise kann fehlerhaftes Verhalten von Ventil- oder Temperaturregelungen zu erheblichen Energieverlusten bei der Raumkonditionierung führen. Mithilfe der automatisierten Anomaliedetektion können auch Ausreißer im Komfortbereich einzelner Räume detailliert untersucht werden. Somit dient die Detektion als Grundlage für die Optimierung des Betriebs von Heiz- und Kühlsystemen in Gebäuden.

Die Ergebnisse der Anomaliedetektion sowie deren Klassifizierung und Relevanzbewertung können zur Verfeinerung des Autoencoders verwendet werden. Die Identifikation von Anomaliegruppen, die keine tatsächlichen betrieblichen Abweichungen darstellen, ermöglicht eine Neukalibrierung des Detektors, um die Genauigkeit zu steigern.

Durch die Klassifizierung der Anomaliegruppen und die Definition ihrer Typen ergeben sich neue Möglichkeiten für zukünftige Geschäftsmodelle. Die charakteristischen Kurven, die sich für jeden Typ ergeben, können die Betriebsoptimierung von Energiesystemen erheblich beschleunigen. Anomalien der Typen „Kurzzeitige Spitzen“ und „flache Linien“ deuten auf zeitweise fehlende Messdaten hin, während „schnelle Änderungen“ und „Temperaturspitzen“ häufig auf fehlerhafte Ventilregelungen zurückzuführen sind.

### **5.2.3. Zusammenfassung Ergebnisse Canvas Methode**

Die Geschäftsmodellkonzepte für drei spezifische Use Cases, die sich auf das Energiemanagement und die Überwachung in Gebäuden fokussieren, wurden entwickelt. Zu Beginn erfolgte eine präzise Definition der Anforderungen für jeden Use Case, wobei die Optimierung der Energieeffizienz, die Verbesserung der Betriebsführung und die frühzeitige Erkennung von Problemen im Mittelpunkt standen. Dabei wurden wichtige Stakeholder wie Technologieanbieter, Facility-Management-Dienstleister und potenzielle Kunden wie Gebäudeeigentümer und Facility Manager identifiziert.

In umfangreichen Brainstorming-Sitzungen wurden verschiedene Strategien erarbeitet, um diese Ziele zu erreichen. Fortschrittliche Technologien wie Künstliche Intelligenz, fortschrittliche Sensorik und maßgeschneiderte Softwarelösungen bildeten dabei den Schwerpunkt der Diskussionen. Diese Ideen wurden systematisch in das Canvas-Modell überführt, wobei Schlüsselemente wie Partnerschaften, Tätigkeiten, Ressourcenallokation, Wertangebote, Kundenbeziehungen, Vertriebskanäle, Zielgruppen, Kostenstrukturen und Einnahmequellen detailliert ausgearbeitet wurden.

Nach der ersten Ausarbeitung wurde das Geschäftsmodellkonzept einer internen Überprüfung unterzogen, um wertvolles Feedback einzuholen und das Modell weiter zu verfeinern. Besonderes Augenmerk lag dabei auf der praktischen Umsetzbarkeit und der Sicherstellung der Machbarkeit der vorgeschlagenen Lösungen. Durch mehrere Iterationen und Anpassungen wurden die Geschäftsmodelle schließlich finalisiert. Diese wurden in einem umfassenden Bericht zusammengefasst, der alle wesentlichen Informationen und strategischen Ansätze für die Implementierung und Vermarktung der Lösungen beinhaltet.

### **5.2.4. Zusammenfassung Ergebnisse Wirtschaftlichkeit**

Eine umfassende Wirtschaftlichkeitsanalyse hat ein neu entwickeltes KI-Tool zur Optimierung des Energiemanagements und der Instandhaltung von Gebäuden untersucht. Ziel dieser Analyse war es, die finanziellen und betrieblichen Vorteile des Tools zu bewerten, das darauf abzielt, den Energieverbrauch zu reduzieren, die Effizienz zu steigern und mögliche Betriebsanomalien frühzeitig zu erkennen. Das Tool richtet sich insbesondere an Unternehmen und Organisationen, die den stetig steigenden Energiepreisen und den wachsenden Anforderungen an Nachhaltigkeit und Effizienz gerecht werden möchten. Die Implementierung moderner Technologien im Gebäudemanagement wird zunehmend unverzichtbar, um diese Herausforderungen langfristig zu meistern.

Das KI-Tool umfasst dabei drei zentrale Funktionen, die zusammenarbeiten, um den Gesamtenergieverbrauch eines Gebäudes deutlich zu senken. Die Hauptziele des Tools sind eine Reduktion des Gesamtenergieverbrauchs um 10 bis 15 %, die frühzeitige Erkennung von Betriebsstörungen und eine verlängerte Lebensdauer technischer Anlagen. Die erste Funktion ist auf die Optimierung der Wärme- und Kälteversorgung in Gebäuden ausgerichtet. Durch kontinuierliche Analyse des Energiebedarfs und eine automatische Anpassung der Heizungs- und Kühlsysteme in Echtzeit kann das Tool den Einsatz von Energiequellen wie Wärmepumpen effizienter gestalten und alternative Energiequellen optimal nutzen. Eine detaillierte Planung des Energieverbrauchs auf Basis von Wettervorhersagen und Nutzungsmustern hilft zusätzlich, Überlastungen zu vermeiden und die Energienutzung zu optimieren. Insgesamt ergibt sich durch diese Funktionen eine erwartete Reduktion des Energieverbrauchs für Heizung und Kühlung um 5 bis 7 %.

Ein weiterer zentraler Aspekt des Tools ist die präzise Vorhersage der thermischen Raumluftzustände. Hierbei setzt das Tool auf KI-gestützte Modelle, um die Bedingungen in unterschiedlichen Gebäudebereichen zu prognostizieren und die Steuerung der Heizungs-, Lüftungs- und Klimaanlage bedarfsgerecht anzupassen. Diese Funktion ermöglicht nicht nur eine gezielte Bereitstellung der

benötigten Energie, sondern steigert gleichzeitig den Komfort der Nutzer im Gebäude. Zudem wird der Energieverbrauch reduziert, da das Tool nur die tatsächlich erforderliche Menge an Energie bereitstellt, um die gewünschten Raumtemperaturen zu erreichen. Diese vorausschauende Steuerung kann den Energieverbrauch um weitere 3 bis 5 % senken.

Die dritte wichtige Funktion des Tools bezieht sich auf die Fehlererkennung im Gebäudeautomationssystem. Durch die kontinuierliche Überwachung der Betriebsabläufe und die Erkennung von Anomalien oder ineffizienten Betriebszuständen trägt das Tool zur Vermeidung von erhöhtem Energieverbrauch bei. Da Betriebsfehler oft unentdeckt bleiben und zu beträchtlichen Energieverlusten führen können, unterstützt diese Funktion die rechtzeitige Identifikation und Meldung solcher Anomalien. So können entsprechende Korrekturmaßnahmen getroffen werden, bevor größere Energieverluste entstehen. Diese Fehlererkennungsfunktion ermöglicht zusätzliche Einsparungen von 2 bis 3 % des gesamten Energieverbrauchs.

In der wirtschaftlichen Analyse wurden die Investitions- und Betriebskosten des KI-Tools sowie die erwarteten Einsparungen durch die Nutzung dieses Tools einander gegenübergestellt. Die Implementierungskosten setzen sich aus den Ausgaben für Hardware, die Integration in die bestehende Infrastruktur und die Schulung des Personals zusammen und belaufen sich insgesamt auf 40.000 €. Die jährlichen Betriebskosten, die unter anderem Lizenzgebühren und Kosten für Support sowie für Datenanalyse und Optimierung umfassen, betragen etwa 30.000 €. Basierend auf einem aktuellen Gesamtenergieverbrauch von 1.672.430 kWh und einem Strompreis von 0,27 € pro kWh wird durch das KI-Tool eine Energieeinsparung von 10 % erwartet, was einer Ersparnis von etwa 45.205 € pro Jahr entspricht. Nach Abzug der Betriebskosten ergibt sich eine Nettoersparnis von etwa 15.205 € jährlich. Die Amortisationszeit für das Tool liegt damit bei rund 2,7 Jahren, sodass die anfänglichen Investitionskosten bereits nach weniger als drei Jahren durch die erzielten Einsparungen gedeckt sind. Nach Ablauf dieser Amortisationszeit führt die erzielte Nettoersparnis zu einer weiteren Verbesserung des Return on Investment (ROI), was die Attraktivität der Investition zusätzlich unterstreicht.

Neben den unmittelbaren finanziellen Einsparungen bietet das KI-Tool auch zahlreiche langfristige Vorteile, die über die reine Reduktion des Energieverbrauchs hinausgehen. Durch die kontinuierliche Optimierung der Gebäudetechnik und die frühzeitige Erkennung von Störungen wird die Lebensdauer technischer Anlagen erhöht, was zu einer Reduktion von Wartungskosten führen kann. Ein weiterer wesentlicher Vorteil ist die erhöhte Nachhaltigkeit im Gebäudebetrieb. Die Reduzierung von CO<sub>2</sub>-Emissionen und die Steigerung der Energieeffizienz entsprechen den heutigen Anforderungen an umweltfreundliche Betriebsweisen und tragen zur Erreichung der Umweltziele der Organisation bei. Ein solch energieeffizientes Gebäude könnte langfristig nicht nur den Marktwert steigern, sondern auch eine positive Auswirkung auf die Bewertung durch potenzielle Investoren oder Mieter haben. Insgesamt zeigt die Analyse, dass das KI-Tool für das Energiemanagement in Gebäuden nicht nur signifikante finanzielle Vorteile bietet, sondern auch zur Optimierung betrieblicher Prozesse beiträgt, die Nachhaltigkeit fördert und den Marktwert des Gebäudes erhöhen kann.

### **5.2.5. Erkenntnisse Wirtschaftlichkeitsbetrachtung**

Die durchgeführte Wirtschaftlichkeitsanalyse des KI-Tools für Energiemanagement und Instandhaltung hat umfassende Erkenntnisse zu den potenziellen Vorteilen und der finanziellen Rentabilität dieser Technologie geliefert. Das analysierte KI-Tool vereint drei entscheidende Funktionen: Energiemanagement der Wärme- und Kälteversorgung, Vorhersage thermischer Raumluftzustandsgrößen sowie Fehlererkennung im Gebäudeautomationssystem. Diese Funktionen sind darauf ausgelegt, den Energieverbrauch eines Gebäudes signifikant zu reduzieren und dessen Betriebseffizienz zu verbessern.

Durch die Implementierung des KI-Tools werden Einsparungen in Höhe von etwa 10 % des Gesamtenergieverbrauchs erwartet. Dies bedeutet konkret, dass bei einem jährlichen Stromverbrauch von 1.672.430 kWh eine Reduktion um 167.243 kWh realisiert werden kann. Bei einem durchschnittlichen Strompreis von 0,27 €/kWh ergeben sich jährliche Einsparungen von ca. 45.205,61 €. Diese Einsparungen stehen im direkten Vergleich zu den jährlichen Betriebskosten des Tools, die sich auf insgesamt 30.000 € belaufen. Diese Kosten setzen sich zusammen aus Lizenzgebühren von 25.000 €, Wartungs- und Supportkosten von 3.000 € sowie zusätzlichen Kosten für Datenanalyse und Optimierungen in Höhe von 2.000 €.

Die anfänglichen Investitionskosten für die Einführung des KI-Tools betragen 40.000 €, was Hardware, Integration, Implementierung und Schulung umfasst. Die Amortisationszeit, also der Zeitraum, innerhalb dessen die Investitionskosten durch die erzielten Einsparungen gedeckt werden, beträgt etwa 2,7 Jahre. Dies bedeutet, dass nach dieser Zeitspanne die Investition vollständig amortisiert ist und fortan eine jährliche Nettoersparnis von etwa 15.205 € erzielt wird. Die Analyse zeigt, dass das KI-Tool nicht nur die Betriebskosten senkt, sondern auch eine signifikante Reduktion der Energiekosten ermöglicht.

Zusätzlich wird festgestellt, dass in Gebäuden mit höherem Energieverbrauch die Vorteile des KI-Tools noch ausgeprägter sein könnten. In solchen Fällen würde die Amortisation der Investition möglicherweise schneller erfolgen und die langfristigen Einsparungen wären entsprechend höher. Diese Erkenntnisse belegen die hohe Wirtschaftlichkeit und die langfristigen finanziellen Vorteile der Investition in das KI-Tool.

Insgesamt verdeutlicht die Analyse, dass das KI-Tool eine wirtschaftlich attraktive Lösung für das Energiemanagement und die Instandhaltung darstellt. Es kombiniert fortschrittliche Technologien mit signifikanten Kosteneinsparungen und einer schnellen Amortisation, was es zu einer lohnenden Investition für Gebäude mit hohem Energieverbrauch macht.

# 6 Schlussfolgerungen

## 6.1. Gewonnene Erkenntnisse Use Case 1

Use Case 1 zeichnete sich durch die Verfügbarkeit langer Datenzeitreihen (>3 Jahre) in hoher Qualität aus, was sich in guten Vorhersagen für die Energiegrößen niederschlug. Weniger genau waren die Vorhersagen des Grundwasserverbrauchs, wahrscheinlich wegen dessen Entnahmegrenzen. Als Weiterentwicklung könnten die Vorhersagen auf drei Tage in die Zukunft ausgedehnt, für die Optimierung des Energieverbrauchs ein Algorithmus zum Setzen von Sollwerten entwickelt und Energiekosten optimiert werden.

## 6.2. Erkenntnisse Use Case 2

Die Prognosen für den thermischen Komfort in Büros erwiesen sich als ungenauer als jene für den Gebäudeenergieverbrauch (UC1). Mögliche Gründe hierfür sind, dass kleinere Einheiten (Räume) generell volatiler sind als größere Einheiten (Gebäude) und dass die verfügbare Datenhistorie deutlich kürzer ist (<1 Jahr). Möglichkeiten für eine Weiterentwicklung liegen insbesondere in der Umsetzung einer Stellgrößenoptimierung wie beim Gebäude-HVAC-Energieverbrauch. Dafür müssten, entgegen der aktuellen Gebäudebetriebspraxis, die relevanten Stellgrößen variiert werden, damit die ML-Modelle die Auswirkungen dieser Variationen kodieren können.

Die wichtigsten Erkenntnisse der funktionellen Evaluierung lassen sich wie folgt zusammenfassen: Die Vorhersagemodelle haben sich als nützliches Instrument zur Vorhersage des thermischen Komforts und zur Verbesserung der Betonkerntemperaturregelung während der Woche erwiesen, damit eine höhere thermische Behaglichkeit erreicht werden kann. Die Vorhersagemodelle wurden durch thermische Komfortmessungen über einen Zeitraum von sechs Wochen validiert und zeigen eine gute Übereinstimmung. Die internen Lasten im Büro, die aufgrund der hohen Belegung und der intensiven Nutzung des Computers für Simulationsaktivitäten resultieren, führen zu hohen Temperaturen während des Tages, die den thermischen Komfort verringern. Aus diesem Grund werden die optimalen Werte für die thermische Behaglichkeit fast nie erreicht, aber in den meisten Fällen liegen die relative Luftfeuchtigkeit und die Lufttemperatur im Bereich von "noch behaglich" laut dem Behaglichkeitsdiagramm von Frank.

## 6.3. Erkenntnisse Use Case 3

Es sind weitere Validierungen seitens des Betreibers erforderlich, um die optimale Auswahl externer und synthetischer Datenpunkte zu ermitteln und so die Erkennung echter Anomalien zu verbessern. Um die Fähigkeit des Modells zur Erkennung von Anomalien weiter zu validieren, bleibt bei Fehlen echter Anomalien im System die Möglichkeit, synthetische Fehler in die Daten einzuführen, um die Erkennung einzelner und multivariater Anomalien zu testen. Der Ansatz, das Brick-Datenmodell zur Auswahl von Datenpunkten zur Spezifikation einzelner Autoencoder zu nutzen, erwies sich als leistungsstark.

## 6.4. Verwertung der Ergebnisse für relevante Zielgruppen

Die Projektergebnisse sind für eine Vielzahl von Zielgruppen relevant und interessant. Eine der zentralen Zielgruppen sind Facility Manager, die für den Betrieb von großen Gebäuden und Infrastrukturen verantwortlich sind. Die entwickelten KI-Tools bieten ihnen eine erhebliche Unterstützung bei der Optimierung der Betriebsführung. Durch die Nutzung der KI können sie nicht nur den Energieverbrauch senken, sondern auch die Betriebskosten minimieren und die Einhaltung behördlicher Vorgaben sicherstellen. Insbesondere in großen Gebäudekomplexen, wie Bürogebäuden, Krankenhäusern oder Einkaufszentren, ist eine solche Unterstützung von großem Wert.

Ein weiteres relevantes Anwendungsfeld liegt in der Industrie. Unternehmen mit hohem Energiebedarf, wie produzierende Betriebe oder Rechenzentren, können von den entwickelten Lösungen besonders profitieren. Hier geht es vor allem darum, den Energieverbrauch zu optimieren und die Betriebseffizienz zu steigern. Durch die Reduktion des Energieverbrauchs lassen sich nicht nur Kosten senken, sondern auch Umweltziele erreichen, was angesichts steigender Anforderungen an die Nachhaltigkeit von Unternehmen immer wichtiger wird. Für die Industrie bietet sich zudem die Möglichkeit, durch frühzeitige Erkennung von Anomalien im Betrieb auf potenzielle Probleme oder Defekte zu reagieren, bevor diese zu Ausfällen führen. Diese können nicht nur die Betriebskosten senken, sondern auch die Betriebssicherheit erhöhen.

Neben den operativen Zielgruppen ist das Projekt auch für Politik und Gesetzgeber relevant, da die entwickelten Technologien dabei helfen können, gesetzliche Vorgaben im Bereich der Energieeffizienz und Ressourcennutzung besser zu überwachen und einzubehalten. Durch den Einsatz der KI-Lösungen können Unternehmen sicherstellen, dass sie gesetzliche Auflagen, wie etwa die Nutzung von Grundwasserressourcen oder die Einhaltung von Energieeinsparzielen, zuverlässig umsetzen. Auch auf Ebene der öffentlichen Hand könnten die Lösungen einen Beitrag zur Einhaltung von Klimazielen leisten, indem öffentliche Gebäude und Infrastrukturen effizienter betrieben werden.

## 6.5. Rechtliche Hürden

Obwohl die entwickelten Technologien vielversprechend sind, müssen auch einige rechtliche Hürden beachtet werden. Eine der wichtigsten Herausforderungen betrifft den Datenschutz. Da die KI-Modelle große Mengen an Betriebs- und Überwachungsdaten sammeln und analysieren, ist es unerlässlich, die bestehenden Datenschutzvorgaben streng einzuhalten. Insbesondere, wenn es um personenbezogene Daten oder Daten geht, die Rückschlüsse auf Verhaltensweisen von Personen zulassen, müssen klare Schutzmaßnahmen ergriffen werden. In der EU müssen die Lösungen den Anforderungen der Datenschutzgrundverordnung entsprechen, was unter anderem bedeutet, dass nur notwendige Daten erhoben werden dürfen und entsprechende Einwilligungen vorliegen müssen. Darüber hinaus stellt die Automatisierung von Prozessen zur Nutzung von Ressourcen, wie etwa Brunnenwasser, eine rechtliche Herausforderung dar. Hier müssen die Betreiber sicherstellen, dass die Entscheidung der KI im Einklang mit den behördlichen Genehmigungen stehen, um Rechtsverstöße oder Geldstrafen zu vermeiden.

Ein weiteres rechtliches Thema ist die Verantwortung bei der Erkennung von Anomalien. Sollte die KI eine Anomalie erkennen, aber diese nicht rechtzeitig behoben werden, stellt sich die Frage, wer für potenzielle Schäden haftet. Es bedarf daher klarer Regelung zur Verantwortung und Haftung bei der Nutzung solcher Systeme, insbesondere in sensiblen Bereichen wie der Energieversorgung oder dem Gebäudemanagement.

## 6.6. Verbreitungsaktivitäten und Marktpotential

Das Marktpotenzial der entwickelten Technologien ist beträchtlich. Mit dem wachsenden Druck zur Dekarbonisierung und den zunehmenden Anforderungen an die Energieeffizienz von Gebäuden und Infrastrukturen bietet das Projekt eine Lösung für aktuelle und zukünftige Herausforderungen. Besonders im Bereich der nachhaltigen Gebäudeoptimierung ist ein wachsender Bedarf an innovativen Lösungen spürbar. Die entwickelten Technologien könnten zudem in weiteren Bereichen Anwendung finden, etwa in der vorausschauenden Wartung von Industrieanlagen oder kritischen Infrastrukturen. Hierbei könnte die KI dazu beitragen, Wartungskosten zu senken und ungeplante Ausfälle zu minimieren.

Langfristig wird der Erfolg der Technologien davon abhängen, wie gut sie an unterschiedliche Marktanforderungen und regulatorische Rahmenbedingungen angepasst werden können. Durch die enge Zusammenarbeit mit Betreibern, Energieversorgern und der Politik könnte das Projekt jedoch eine Schlüsselrolle in der zukünftigen Entwicklung energieeffizienter und nachhaltiger Infrastrukturen spielen.

# 7 Ausblick und Empfehlungen

## 7.1. Empfehlungen für weiterführende Forschungs- und Entwicklungsarbeiten

Im Rahmen des Projekts mAMaintenance wurde gezeigt, wie Anomaliedetektoren auf Basis von Autoencodern für Systeme, Subsysteme und räumliche Bereiche automatisch generiert werden können, indem die semantischen Informationen über die Anlage und ihre Systeme genutzt werden. Einer der Hauptschwerpunkte zukünftiger Arbeiten sollte die Validierung der Ergebnisse sein, die Anomaliedetektoren unter Verwendung gekennzeichnete Datensätze liefern, sowie die weitere Feinabstimmung des Modellentwicklungsprozesses und insbesondere der Datenauswahl- und Datenaufbereitungsmethoden. Das Potenzial für die Wiederverwendung von Modellen in verschiedenen Anlagen muss ebenfalls bewertet werden, wobei weitere Arbeiten zum Testen und Anpassen des Prozesses zur automatischen Generierung von Anomalieerkennungsmodellen erforderlich sind. Für die Komponenten, an denen die Anlagenmanager am meisten interessiert sind, könnte eine Toolbox mit Abfragen entwickelt werden, um die schnelle Generierung optimaler Anomaliedetektoren für die jeweilige Anlage zu ermöglichen. Darüber hinaus wird die Integration des Feedbacks des Systembetreibers zu entdeckten Anomalien derzeit im Umschulungsprozess nicht berücksichtigt. Schließlich sollten Leistung und Wiederverwendbarkeit der entwickelten Workflows verbessert werden, um die weitere Entwicklung zu beschleunigen.

## 7.2. Potenzial für Demonstrationsvorhaben (Chancen / Herausforderungen / Risiken bei der Realisierung / Umsetzung in Richtung Demonstrationsprojekt)

Die in mAMaintenance entwickelte Toolbox ist für die Entwicklung in weiteren Projekten anpassbar. Ein idealer Pilotstandort für die weitere Entwicklung würde eine Einrichtung mit vorhandener semantischer Beschreibung guter Qualität, Überwachungsdaten von zufriedenstellender Qualität und eine gewisse Menge gut dokumentierter Systemausfälle mit unterstützenden Daten von betroffenen Systemen und Subsystemen für Zeiträume vor, während und nach dem Ausfall umfassen. Einblicke des Systembetreibers in Systeminteraktionen vor und während Anomaliebedingungen können weitere Informationen darüber liefern, wie die Anomalieerkennung verbessert werden kann (z. B. durch Ändern der Struktur generierter Anomaliedetektoren für bestimmte System- oder Subsystemtypen). Dies würde eine Validierung des Vorhersagepotenzials, der Genauigkeit und Präzision entdeckter Anomalien des Anomaliedetektors ermöglichen und zu Verbesserungen der Anomalieerkennung führen.

# 8 Verzeichnisse

## 8.1. Abbildungsverzeichnis

Abbildung 1: Grundlegendes RDF-Diagramm .....	17
Abbildung 2: Legende verwendeter BRICK Klassen.....	18
Abbildung 3: Partizipationsprozess des Anforderungsspezifizierung .....	19
Abbildung 4: Installation Edge Device (im GLT PC Raum) .....	22
Abbildung 5: BRICK Datenmodell (Auszug HLK-Systeme innerhalb des GAS).....	25
Abbildung 6: BRICK Datenmodell (Auszug des IoT Sensornetzwerks) .....	26
Abbildung 7: Konzept zur Kommunikation zwischen den Komponenten.....	26
Abbildung 8: Arbeitsablauf der Datenverarbeitung und Anomaliedetektor-Training.....	31
Abbildung 9: Schematische Darstellung der symmetrischen Autoencoder-Architektur mit variabler Anzahl interner Schichten .....	31
Abbildung 10: Wahrer und vorhergesagter Energieverbrauch des HLK-Systems sowie die Außentemperatur für einen repräsentativen Zeitraum im Sommer 2023 .....	34
Abbildung 11: Wahrer und optimierter vorhergesagter Energieverbrauch des HLK-Systems für einen ausgewählten Tag im Sommer 2023 .....	34
Abbildung 12: Wahre und vorhergesagte Raumtemperatur und -luftfeuchtigkeit im betrachteten Raum 1.107 für einen Zeitraum im Sommer 2023.....	35
Abbildung 13: Behaglichkeitsdiagramm mit der Raumtemperatur- & -luftfeuchtigkeitsvorhersage im betrachteten Raum 1.107 für einen Drei-Tages-Zeitraum im Sommer 2023. Die farbigen Punkte repräsentieren 36 verschiedene Zeitpunkte in diesem Zeitraum.....	36
Abbildung 14: Rekonstruktionsfehlerschwellenwerte .....	37
Abbildung 15: Büroklimacharakterisierung ohne Aktivierung der Betonkerntemperatur .....	39
Abbildung 16: CO2-Konzentration .....	40
Abbildung 17: Vorhersagen zum thermischen Komfort vom 17. bis 21. Juni.....	41
Abbildung 18: Büroklimacharakterisierung nach der Betonkernaktivierung vom 17. bis 21. Juni .....	43
Abbildung 19: CO2-Konzentration vom 17. bis 21. Juni.....	43
Abbildung 20 - Anomalientyp: Flache Linien.....	46
Abbildung 21 - Anomalientyp: Schnelle Änderungen .....	47
Abbildung 22 - Anomalientyp: Temperaturspitzen.....	48
Abbildung 23: Für Abbildungen fügen Sie bitte Beschriftungen darüber mit automatisch fortlaufender Nummerierung und Quellenangaben ein. Formatvorlage: „Beschriftung“ .....	<b>Fehler! Textmarke nicht definiert.</b>

## 8.2. Tabellenverzeichnis

Tabelle 1: Zusammenfassung der identifizierten Methoden .....	15
---	----

Tabelle 2: Use Case Anforderungen .....	20
Tabelle 3: verwendete IoT-Sensoren.....	23
Tabelle 4: Root Mean Square Error (RMSE) der verschiedenen ML-Modelle in Use Case 1 .....	33
Tabelle 5: Root Mean Square Error (RMSE) der ML-Modelle für den betrachteten Raum 1.107 .....	35
Tabelle 6: Rekonstruktionsfehlerschwelle und Eigenschaften der besten Modelle jeder Kategorie (System, Verzögerungen) .....	36
Tabelle 7: Messplan für die Evaluierung der thermischen Behaglichkeit .....	39
Tabelle 8: Betonkerntemperatur Aktivierung zwischen dem 17. und 21. Juni .....	42
Tabelle 9 - Anomalienklassifizierung .....	44
Tabelle 100: Beispiel für die Beschreibung der Daten, welche im Rahmen des Projekts verwendet werden .....	<b>Fehler! Textmarke nicht definiert.</b>
Tabelle 111: Beispiel für die Beschreibung der Daten, welche im Projekt generiert werden .....	<b>Fehler! Textmarke nicht definiert.</b>
Tabelle 122: Beispiel für die Beschreibung der Metadaten im Projekt .....	<b>Fehler! Textmarke nicht definiert.</b>
Tabelle 133: Für Tabellen fügen Sie bitte Beschriftungen darüber mit automatisch fortlaufender Nummerierung ein. Formatvorlage: „Beschriftung“ / Alternativtext unter „Tabelleneigenschaften“ einfügen.....	<b>Fehler! Textmarke nicht definiert.</b>

### 8.3. Literaturverzeichnis

- Afram A., Janabi-Sharifi F.: Theory and applications of HVAC control systems—A review of model predictive control (MPC). In: Building and Environment, 72, S. 343–355. 2014.
- Amasyali K., El-Gohary N.M.: A review of data-driven building energy consumption prediction studies. In: Renewable and Sustainable Energy Reviews, 81, 1192–1205. 2018.
- Araya D. B., Grolinger K., ElYamany H. F., Capretz M. A. M., Bitsuamlak G.: Collective contextual anomaly detection framework for smart buildings. In: 2016 International Joint Conference on Neural Networks (IJCNN), 511–518. Vancouver, Kanada 2016. <https://doi.org/10.1109/IJCNN.2016.7727242>.
- Balaji B., Bhattacharya A., Fierro G., Gao J., Gluck J., Hong D., Johansen A., Koh J., Ploennigs J., Agarwal Y., Bergés M., Culler D., Gupta R. K., Kjærsgaard M. B., Srivastava M., Whitehouse K.: Brick: Metadata schema for portable smart building applications. Applied Energy, 226, S.1273–1292. 2018a. <https://doi.org/10.1016/j.apenergy.2018.02.091> (Zitiert S. 16)
- Balaji B., Bhattacharya A., Fierro G., Gao J., Gluck J., Hong D., Johansen A., Koh J., Ploennigs J., Agarwal Y., Bergés M., Culler D., Gupta R. K., Kjærsgaard M. B., Srivastava M., Whitehouse K.: Brick: Metadata schema for portable smart building applications. Applied Energy, 226, S.1273–1292. 2018b. <https://doi.org/10.1016/j.apenergy.2018.02.091> (Zitiert S. 18)
- Bloemheuvel S., Hoogen J. van den, Jozinović D., Michelini A., Atzmueller M.: Multivariate Time Series Regression with Graph Neural Networks. 2022. <https://doi.org/10.48550/arXiv.2201.00818>
- Chollet F. and others: Keras. 2015. Available at: <https://keras.io>.
- Daniele L., den Hartog F., Roes J.: Created in Close Interaction with the Industry: The Smart Appliances REference (SAREF) Ontology. In: Cuel, R., Young, R. (Hrsg.): Formal Ontologies Meet

Industry, Springer International Publishing, S. 100–112. Cham 2015. [https://doi.org/10.1007/978-3-319-21545-7\\_9](https://doi.org/10.1007/978-3-319-21545-7_9).

De Gooijer J. G., Hyndman R. J.: 25 years of time series forecasting. *International Journal of Forecasting*, 22(3), S. 443–473. 2006.

Deb C., Zhang F., Yang J., Lee S.E., Shah K.W.: A review on time series forecasting techniques for building energy consumption. In: *Renewable and Sustainable Energy Reviews* 74, S. 902-924. 2017a. (Zitiert S. 12)

Deb C., Zhang F., Yang J., Lee S.E., Shah K.W.: A review on time series forecasting techniques for building energy consumption. In: *Renewable and Sustainable Energy Reviews* 74, S. 902-924. 2017b. (Zitiert S. 31)

Goodfellow I., Bengio Y., Courville A.: *Deep learning*. The MIT Press. 2016a. (Zitiert S. 12)

Goodfellow I., Bengio Y., Courville A.: *Deep learning*. The MIT Press. 2016b. (Zitiert S. 12)

Goodfellow I., Bengio Y., Courville A.: *Deep learning*. The MIT Press. 2016c. (Zitiert S. 13)

Goodfellow I., Bengio Y., Courville A.: *Deep learning*. The MIT Press. 2016d. (Zitiert S. 13)

Grüne L., Pannek J.: *Nonlinear model predictive control: Theory and algorithms*. Second edition, Springer, Cham 2017a. <https://doi.org/10.1007/978-3-319-46024-6> (Zitiert S. 14)

Grüne L., Pannek J.: *Nonlinear model predictive control: Theory and algorithms*. Second edition, Springer, Cham 2017b. <https://doi.org/10.1007/978-3-319-46024-6> (Zitiert S. 14)

Hamilton I., O'Rourke D., Rees W., Wilton J., Daugherty M.: *Global Status Report for Buildings and Construction: Towards a Zeroemission, Efficient and Resilient Buildings and Construction Sector*. United Nations Environment Programme, Nairobi, 2022.

Hayes M. A., Capretz M. A. M.: Contextual anomaly detection framework for big sensor data. In: *Journal of Big Data*, 2(1), S. 2. 2015. <https://doi.org/10.1186/s40537-014-0011-y>.

Ho S., Xie M., Goh T.N.: A comparative study of neural network and Box-Jenkins ARIMA modeling in time series prediction. In: *Computers & Industrial Engineering*, 42(2–4), S. 371–375. 2002.

Hochreiter S., Schmidhuber J.: Long Short-Term Memory. In: *Neural Computation*, 9(8), S. 1735–1780. 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>.

Kathirgamanathan A., De Rosa M., Mangina E., Finn D. P.: Data-driven predictive control for unlocking building energy flexibility: A review. In: *Renewable and Sustainable Energy Reviews*, 135, S. 110120. 2021.

Kipf T. N., Welling M.: Semi-supervised classification with graph convolutional networks. In: arXiv, 2017. <https://arxiv.org/abs/1609.02907>.

Lara-Benítez P., Carranza-García M., Luna-Romera J. M., Riquelme J. C.: Temporal Convolutional Networks Applied to Energy-Related Time Series Forecasting. In: *Applied Sciences*, 10(7), S. 7. 2020. <https://doi.org/10.3390/app10072322>.

Li L., Jamieson K. G., DeSalvo G., Snoek J.: Hyperband: A novel bandit-based approach to hyperparameter optimization. In: *Journal of Machine Learning Research*, 18(185), S. 1–52. 2018.

Mtibaa F., Nguyen K.-K., Dermardiros V., Cheriet M.: Context-aware Model Predictive Control framework for multi-zone buildings. In: *Journal of Building Engineering*, 42, S. 102340. 2021a. <https://doi.org/10.1016/j.jobe.2021.102340>. (Zitiert S. 14)

Mtibaa F., Nguyen K.-K., Dermardiros V., Cheriet M.: Context-aware Model Predictive Control framework for multi-zone buildings. In: *Journal of Building Engineering*, 42, S. 102340. 2021b. <https://doi.org/10.1016/j.jobe.2021.102340>. (Zitiert S. 14)

Pang G., Shen C., Cao L., Hengel A. van den: Deep Learning for Anomaly Detection: A Review. *ACM Computing Surveys*, 54(2), 1–38. 2022a. <https://doi.org/10.1145/3439950> (Zitiert S. 16)

Pang G., Shen C., Cao L., Hengel A. van den: Deep Learning for Anomaly Detection: A Review. *ACM Computing Surveys*, 54(2), 1–38. 2022b. <https://doi.org/10.1145/3439950> (Zitiert S. 33)

Pauwels P., Terkaj W.: EXPRESS to OWL for construction industry: Towards a recommendable and usable ifcOWL ontology. In: *Automation in Construction*, 63, S. 100–133. 2016. <https://doi.org/10.1016/j.autcon.2015.12.003>.

Rangapuram S. S., Seeger M. W., Gasthaus J., Stella L., Wang B., & Januschowski T.: Deep state space models for time series forecasting. In: Bengio Samy, Wallach Hanna, Larochelle Hugo, Grauman Kristen, Cesa-Bianchi Nicolò, Garnett Roman (Hrsg.): *Advances in Neural Information Processing Systems* (Band 31). Curran Associates, Inc., 2018.

Rasmussen M. H., Lefrançois, M., Schneider, G. F., Pauwels, P.: BOT: The building topology ontology of the W3C linked building data group. In: *Semantic Web*, 12(1), 143–161. 2021. <https://doi.org/10.3233/SW-200385>.

Russel S., Norvig P.: *Artificial Intelligence: A Modern Approach*. 4. US-Ausgabe, Pearson, n. d..

Schirrer A., Brandstetter M., Leobner I., Hauer S., Kozek M.: Nonlinear model predictive control for a heating and cooling system of a low-energy office building. *Energy and Buildings*, 125, S. 86–98. 2016. <https://doi.org/10.1016/j.enbuild.2016.04.029>

Shi Z., O'Brien W.: Development and implementation of automated fault detection and diagnostics for building systems: A review. In: *Automation in Construction*, 104, S. 215–229. 2019. <https://doi.org/10.1016/j.autcon.2018.06.019>.

Sutton R. S., Barto A. G.: *Reinforcement learning: An introduction*. 2. Auflage, MIT Press, 2018. <https://web.stanford.edu/class/psych209/Readings/SuttonBartoIPRLBook2ndEd.pdf>.

Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A., Kaiser L., Polosukhin I.: Attention Is All You Need. In: *ArXiv*, 2017. <https://doi.org/10.48550/arXiv.1706.03762>.

Wang Y., Chen Q., Hong T., Kang C.: Review of Smart Meter Data Analytics: Applications, Methodologies, and Challenges. In: *IEEE Transactions on Smart Grid*, 10(3), S. 3125–3148. 2019.

Zhou H., Zhang S., Peng J., Zhang S., Li J., Xiong H., Zhang W.: Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. In: *ArXiv*, 2021a. <http://arxiv.org/abs/2012.07436>. (Zitiert S. 13)

Zhou H., Zhang S., Peng J., Zhang S., Li J., Xiong H., Zhang W.: Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. In: ArXiv, 2021b. <http://arxiv.org/abs/2012.07436>.  
(Zitiert S. 17)

# 9 Anhang

## 9.1. Data Management Plan (DMP)

### 1: Datenerstellung und Dokumentation

Wie werden neue Daten gesammelt und/oder alte Daten wiederverwendet?

*BACnet-Daten werden über die aedifion Cloud-Plattform gesammelt und archiviert. Über eine API kann auf die Cloud-Plattform zugegriffen werden und die archivierten Datensätze der im Gebäude-automationssystem befindlichen Datenpunkte heruntergeladen werden.*

*IoT-Datensätze werden über das IoT-Netzwerk und einem Raspberry-Pi gesammelt. Anschließende Datenspeicherung erfolgt auf einer SD-Karte, von welcher die Datensätze heruntergeladen werden.*

*Wetterdaten werden über die Meteonorm (historische) bzw. OpenMeteo (Vorhersagedaten) bezogen.*

- Welche Daten (Art, Format, Volumen) werden gesammelt oder produziert?

Betreffend der Datenart und -format siehe Tabelle 1. Das Datenvolumen für gesammelte BACnet-Betriebsdaten liegt im Bereich von

- Welche Metadaten bzw. Dokumentation (z.B. Methoden der Datensammlung und Datenorganisation) werden die Daten begleiten?
- Welche Maßnahmen zur Datenqualitätskontrolle werden verwendet?

Tabelle 10: Beispiel für die Beschreibung der Daten, welche im Rahmen des Projekts verwendet werden

Beschreibung	Typ	Art	Quelle	Zugang	Link
Operative Betriebs- und Zustandsdaten	Numerisch (.csv)	Historische Zeitreihen (historische Daten)	AIT intern	BACnet	Internal data
Raumdaten von IoT-Sensornetz	Numerisch (.csv)	Historische Zeitreihen (historische Daten)	AIT intern	Gateway	Internal data
Wetterdaten	Numerisch (.csv)	Historische Zeitreihen (historische Daten) sowie Prognose	Openmeteo, meteonorm	?	Internal data
Datenmodell (Ontologie)	Textual (.ttl)	Semantic description of facility, systems, subsystems, existing automation	AIT internal	Server	Internal data

		system's and supplemental IoT network's datapoints			
Dokumente (Schemata, etc)	Textual/graphical (.pdf, .doc)	Descriptions of systems, structures, subsystem connectivity and datapoint details	PKE	Server	Internal data

Tabelle 11: Beispiel für die Beschreibung der Daten, welche im Projekt generiert werden

ID	Beschreibung	Typ	Art	Verantwortlich	Zugang
FEAT_01	Vorhersage Gebäudeenergiebedarf				
FEAT_02	Vorhersage Grundwasserentnahme				
FEAT_03	Vorhersage Raumlufttemperatur				
FEAT_04	Vorhersage rel. Raumluftfeuchtigkeit				
FEAT_05	Vorhersage Betonkerntemperatur				
FEAT_06	Anomaly detection model	binary	Deep learning model	AIT	Not public
FEAT_07	Anomaly score	Floating point time series	Set of anomaly score time series generated by the corresponding anomaly detection model for the target datapoint subset	AIT	Not public

Tabelle 12: Beispiel für die Beschreibung der Metadaten im Projekt – Use Case 3

Attribut	Beschreibung
ID	Futurebase_<subsystem>_<lags>_<layers>_<encoding_size>_<learning_rate>
Titel	Anomaly probability
Zusammenfassung	Dataset consists of multiple separate time series indicating probability of a corresponding measurement recorded for the source datapoint being an anomalous reading. Probability is based on the difference between the real measurement, and value reconstructed using the autoencoder trained over historical data of corresponding datapoints.
Kurzbezeichnung	Dataset contains a time series of probabilities of a measurement being an anomaly.
Einheit	Anomaly probabilities range from 0 to 1. Corresponding measurement values retain original units.
Zeitintervall	on change
Zeitraum und Referenzjahr	2022-2024
Institution	www.ait.ac.at
Kontakt	Milos.sipetic@ait.ac.at
Mitwirkende und Rolle	-
Methodik	autoencoder-based input value reconstruction and probability calculation based on dynamic difference between reconstructed and true value
Datenvervollständigung	Generated probabilities are based on cleaned and prepared input data. Probabilities are not generated for time intervals in which data quality prevents algorithm operation
Quelldaten	Futurebase BMS (PKE, Aedifion), IoT data sources (internal), Weather data (Meteonorm)
Kommentar	
Erstellungsdatum	10.2022-06.2024
Datentyp	comma separated values
Versionsstand	Large number of experiments was performed and for each trained model a number of prediction tests was performed for different time periods. Due to this there is no definitive data version. Generated datasets are rather related to corresponding source machine learning model.

## 2: Ethische, rechtliche und Sicherheitsaspekte

- Wenn personenbezogene Daten verarbeitet werden, wie wird die Einhaltung der Rechtsvorschriften zum Schutz personenbezogener Daten und zur Datensicherheit gewährleistet?

*Bei Antragstellung ist keine Nutzung von personenbezogenen Daten geplant. Falls dies sich im Projektverlauf ändert, hält sich das Konsortium an geltenden Datenschutzgesetzen.*

*Bei Antragstellung sind keine ethischen Aspekte der Daten bekannt. Falls dies sich im Projektverlauf ändert, hält sich das Konsortium im Umgang mit Daten an das von der Europäischen Kommission veröffentlichte Dokument Ethics for researchers und den European Code of Conduct for Research Integrity.*

### **3: Datenspeicherung und -erhalt**

- Wie werden Daten und Metadaten gespeichert und gesichert (back up) während der Projektlaufzeit?

*Daten und Metadaten werden auf einem gemeinsamen Sharepoint des AIT gespeichert, von dem in regelmäßigen Abständen standardmäßig Backups gemacht werden (AIT ITO-Abteilung). Die Wiederherstellung kann von Projektmitarbeitern und/oder durch den IT-Support des AIT durchgeführt werden.*

- Wie wird Acht auf Data Security & Protection von sensiblen Daten während des Projekts genommen.

*Über personalisierte Zugangsdaten und Vergabe von grundlegenden Rechten („kann bearbeiten“, „kann anzeigen“) ermöglicht und reguliert der Datensteward den individuellen Zugriff auf die Daten innerhalb des Konsortiums. Die anzuwendenden Datenschutzrichtlinien sind im Konsortialvertrag geregelt.*

- Wie werden die Daten für die Aufbewahrung ausgewählt und wo werden die Daten langfristig aufbewahrt (z. B. in einem Datenrepository oder Archiv)?

*Daten und Metadaten werden auf den Laufwerken des AIT für die Langzeitarchivierung und Nachnutzung gespeichert.*

### **4: Wiederverwendbarkeit der Daten**

- Wie und wann werden Daten weitergegeben? Gibt es mögliche Einschränkungen bei der Datenweitergabe oder Embargogründe?

*Zur Nachnutzung bei etwaigen kooperativen Folgeprojekten werden die Nutzungsrechte im Zuge der Projektentwicklung und rechtlichen Gestaltung fallweise beurteilt.*

## 9.2. Use Case Beschreibungen

### 9.2.1. Use Case 1 Anforderungen

Title	Energy management for heating / cooling supply system		UC ID-Nr.:	1
Description:	<p>This use case serves to minimize electrical energy costs (=goal of use case) by optimizing the plant operation of heating / cooling supply system. This means a selection of a defined operating mode (OpMo) by the developed AI tool, which decides whether the well system is to be used or not and takes the integration of alternative cooling sources (free cooling via dry coolers) also into account.</p> <p>The operating modes to be selected depend on the season:</p> <ul style="list-style-type: none"> <li>• OpMo 1 during heating</li> <li>• OpMo 4, OpMo 5, OpMo 6 &amp; OpMo 7 during cooling</li> <li>• as OpMo 3 during transitional period</li> </ul> <p>The graphically presented proposal includes a timetable for the next 2 to 3 days, including relevant key performance indicators such as energy consumption and costs. Variables are the "Ausbaugrad" and the limit values between operating modes (limit temperature between winter operation and transition currently 12.5 °C, limit temperature between transition and summer operation currently 14.5 °C, limit value outside humidity 13.5 g/kg). A reduction of electrical energy costs is achieved by simultaneously considering the level of ground water consumption.</p> <p>The variable „Ausbaugrad“ is a binary command (low/high), that decides whether the supply system is cooled during the cooling via the well system („Ausbaugrad high“) or by the chiller („Ausbaugrad low “).</p>			
Non-goals	Planning / maintenance of supply system, energy management of heating- and cooling distribution. No automatically take over of operational state from BAS.			
Stakeholder:	operator, team leader energy manager			
	authority (control function)	Main actor:	operator	
Pre-conditions:	<p>External data:</p> <ul style="list-style-type: none"> <li>• Weather forecast for the next 72h in a resolution of 1h: <ul style="list-style-type: none"> <li>○ ambient temperature, radiation, wind velocity, humidity, degree of cloud cover</li> <li>○ Static data:building- &amp; plant data for transfer learning</li> </ul> </li> <li>• electricity rate</li> </ul>		<p>Process related information_(conditions regarding the applicability of the use case)</p> <p>Irrelevant at:</p> <ul style="list-style-type: none"> <li>• The use case is not relevant when the outside temperatures are low. (only OpMo 1 is possible)</li> </ul> <p>Relevant at:</p> <ul style="list-style-type: none"> <li>• cooling: OpMo 4, OpMo 5, OpMo 6 &amp; OpMo 7</li> <li>• transition period: OpMo 3</li> </ul>	

	<p>Operational data (all available meters that are necessary for this use case and available are listed in detail in the appendix. If a data point is not listed, it is not available as detailed information, e.g. sub-meter load profile pumps):</p> <ul style="list-style-type: none"> <li>• power consumption heat pump</li> <li>• power consumption re-cooler</li> <li>• load profiles of heat / cold generation</li> <li>• time series mass flows and temperatures on source side</li> <li>• history of operation states.</li> </ul> <p>Attention: when interpreting the data, pay attention to any COVID-19 "special behavior"..</p>	<p>conditions for ground water consumption:</p> <ul style="list-style-type: none"> <li>• annual ground water consumption: cooling 168.000 m<sup>3</sup></li> <li>• annual ground water consumption heating 71.000 m<sup>3</sup></li> <li>• daily ground water consumption 2.236 m<sup>3</sup>/d (hard condition, saved by BAS)</li> <li>• temperature limits: 19 °C max. temperature, 5 °C min. temperature</li> </ul> <p>temperature limits of operating modes (see description)</p>
<p>Post-conditions:</p>	<p>As a result, the tool should provide recommendations &amp; forecasts:</p> <ul style="list-style-type: none"> <li>• The recommendations are summarized in a "timetable" for the next 2 to 3 days. The time horizon of 2 to 3 days is chosen in such a way that absences from management (including weekends) are covered and good weather forecasts are possible. The timetable conceptually corresponds to a sequence of operating modes. Any random sequences of operation states cannot be executed. Variables are the Ausbaugrad and the limit temperatures between operating modes. However, these should not change too often throughout the day, as this would not be applicable, since the parameters are not intended to be adopted due to safety concerns (qualitative concerns about room comfort).</li> <li>• Forecasts complement and justify the recommendations. <ul style="list-style-type: none"> <li>○ <u>WHAT</u>: energy consumption, energy costs, well water withdrawal, transitions between operating modes (incl. due to exceeding the daily well water withdrawal limit)</li> <li>○ <u>HOW</u>: <ul style="list-style-type: none"> <li>▪ for the time horizon of the recommendations, with a time step of 15 to 60 minutes, depending on the use case. Monitoring data/changes could be used as an indicator.</li> <li>▪ Longer-term projections of well water abstraction considering the annual limits of well water abstraction. Empfehlungen für Betriebszeiten (Entnahme) wären hier von Interesse</li> </ul> </li> <li>○ <u>WHICH SCENARIOS</u>: for the plant operation resulting from current operating mode and for recommended timetable.</li> </ul> </li> </ul>	

	<ul style="list-style-type: none"> <li>○ Representation of the energy saved within the time series.</li> </ul> <p>NOTICE (current process flow):</p> <ul style="list-style-type: none"> <li>• Meter readings are read once a month and entered in the meter list (object-dependent Excel). The information is passed on to the "energy manager" if there are major deviations that cannot be "explained". This is followed by analysis and an attempt to solve the problem</li> </ul>
<p>Process flow</p>	<ol style="list-style-type: none"> <li>1. Recording of operating data (continuously)</li> <li>2. Update of AI-algorithm with current operating data (regularly)</li> <li>3. Calling up the AI algorithms with current operating data and creating recommendations. The algorithm should calculate automatically and make its recommendations twice a day: in the morning and in the evening, to react accordingly for the same day or the next.  NOTICE: Note changes in the weather forecast. If the weather has a major impact and the weather forecast only changes once a day, does it make sense to have two recommendations a day?</li> <li>4. Recommendations and forecasts should be presented in an understandable way. Here, for example, diagrams / tables with the appropriate set values can be used as a summary. However, a representation similar to the BAS should also be chosen so that changes can be easily found visually. Pay attention to the front end.</li> <li>5. Feedback from the operator on the recommendations and, if necessary, implementation of the recommendations. Attention should be paid to a simple feedback system, e.g. traffic light system, with an additional option of textual input. This information is then central for the validation of the algorithms (AP6). In the front end, attention should be paid to a possibly machine-readable evaluation option (e.g. selectable feedback text, etc.).</li> <li>6. Based on the manager's decision, both forecast and actual data such as energy consumption, costs and savings go to energy managers. Long-term forecasts of what was planned and what was actually achieved would be interesting. Here, however, it must also be transmitted for the evaluation whether recommendations have also been implemented in practice. The aim would be to have a benchmark option.</li> </ol>
<p>Benefit:</p>	<p>Technical:</p> <ul style="list-style-type: none"> <li>• Reduction of electrical power consumption from the heat pump</li> <li>• Compliance with official requirements for groundwater consumption</li> <li>• Avoidance of excessive equipment cycling</li> </ul> <p>Economical:</p> <ul style="list-style-type: none"> <li>• Reduction of electricity costs</li> <li>• Avoidance of fines for non-regulatory usage regarding groundwater</li> </ul>

AI methodology:	<ul style="list-style-type: none"> <li>• Supervised Learning of time series <ul style="list-style-type: none"> <li>○ recurrent neural networks</li> <li>○ 1D convolutional networks</li> <li>○ transfer learning</li> <li>○ for comparison: classic statistical methods of time series forecasts</li> </ul> </li> <li>• derivation of recommendations: <ul style="list-style-type: none"> <li>○ forecasts for various scenarios</li> <li>○ model predictive control with black box (see above)</li> <li>○ reinforcement learning (limited by the fact that interaction with the real system is practically impossible)</li> </ul> </li> </ul>
-----------------	---

### 9.2.2. Use Case 2 Anforderungen

Title:	<b>Energy management of heating &amp; cooling distribution – CCA</b>	UC ID-Nr.:	2
description:	<p>This use case serves to optimize the operation of the concrete core activation from the heating / cooling distribution system. Therefore, thermal energy demand as well as the thermal comfort in the office rooms must be considered as criteria. In particular, minimizing energy consumption includes avoiding (simultaneous) intermittent heating and cooling within the concrete core. The assessment of thermal comfort is mainly based on temperature measurements in relevant zones. In addition, consideration could be given to conducting a simplified user survey, especially in the critical zones. The indicators of thermal discomfort to be minimized are e.g. temperature violations during typical office hours (7:00-19:00).</p>		
Non-goals	Maintenance of heating / cooling distribution system, energy management of heating / cooling supply system (UC1)		
Stakeholder:	operator energy manager employees in offices		
		Main actor:	operator
Pre-conditions:	<p>External data:</p> <ul style="list-style-type: none"> <li>• weather forecast for the next 72h in a resolution of 1h: ambient temperature, radiation, wind velocity, humidity, degree of cloud cover</li> </ul> <p>Operational data (all available meters that are necessary for this use case but are also available are listed in detail in the appendix. If a data point is not listed, it is not available as detailed information, e.g. sub-meter load profile pumps):</p>	<p>Process related information:</p> <ul style="list-style-type: none"> <li>• average outside temperature over the last 72 h, is taken as input for the set-point temperature of ceiling</li> <li>• room temperature setpoint</li> <li>• concrete core temperature setpoint</li> <li>• heating curve: specifies setpoint temperature of concrete core, in dependence of average outside temperature and room influence (see appendix)</li> <li>• hysteresis heating/cooling</li> </ul>	

	<ul style="list-style-type: none"> <li>• load profiles from heating- and cooling distribution system</li> <li>• time series of mass flows and temperatures on dissipation side</li> <li>• 1 heat meter for heating (CCA, floor heating)</li> <li>• 1 cold meter for cooling (CCA, floor heating, sails)</li> <li>• time series room temperature per zone</li> <li>• time series concrete core temperature per zone</li> <li>• control signals from actuators (control valve, switching valve)</li> <li>• setpoint of thermal zone</li> </ul>	
	<p>Meta data: room data e.g. m<sup>2</sup> or which rooms are combined into a thermal zone. (see appendix)</p>	
<p>Post-conditions:</p>	<p>As a result, the AI tool should provide recommendations and forecasts:</p> <ul style="list-style-type: none"> <li>• forecasts for (selected or critical) zone: How will the room temperature and concrete core temperature develop over the next 2 to 3 days? How will the control valves behave?</li> <li>• recommendations for the operation of thermal energy distribution and delivery (especially concrete core activation, but also floor and wall heating/cooling) in the different zones. The time horizon of 2 to 3 days is chosen in such way that absences from operation staff (incl. weekend) are covered and good weather forecasts are possible. The actual variables are: <ul style="list-style-type: none"> <li>○ setpoint-changes of room air temperature</li> <li>○ setpoint-changes of ceiling temperature via parameter “heating curve” (X1 to X4, Y1 to Y4) or parameter “room influence” (2 K to warm, to cold)</li> <li>○ additional components for heating and cooling delivery system: control levels for fan-coils</li> <li>○ holistic blinds-activation per facade</li> </ul> </li> </ul> <p>At the request of the operator, the recommendations should lead to good, controlled behavior (seasonal). However, faults (solar load) could quickly become problematic.</p> <p>For reasons of usability, the recommendations should be limited as far as possible, both in the frequency of the recommendations and in the number of affected zones.</p>	

Process flow:	<ol style="list-style-type: none"> <li>1. Recording of operational data (continuous)</li> <li>2. Updating the AI algorithm with current operational data (regularly)</li> <li>3. Calling up the AI algorithm with current operational data and creating recommendations. The algorithm should calculate automatically and make its recommendations twice a day: in the morning and in the evening, so you can react accordingly for the same day or the next.</li> <li>4. Recommendations and forecasts should be presented in an understandable way. Here, for example, diagrams / tables with corresponding set values can be used as a summary. However, a representation similar to the FM dashboard should be chosen so that changes can be easily found visually. (see front-end development!)</li> <li>5. Attention should be paid to a light feedback system, e.g. traffic light system, with an additional option of textual input. This information plays an important role for the validation of the algorithms (WP6). In the front end, attention should be paid to a machine-readable evaluation option (e.g. selectable feedback text, etc.).</li> </ol>
Benefit:	<p>technical:</p> <ul style="list-style-type: none"> <li>• reduction of heating, cooling and electrical power demand</li> <li>• optimization of thermal comfort criterias</li> <li>• avoidance of overcooling, d.h. sequential switching between heating and cooling</li> </ul> <p>economical:</p> <ul style="list-style-type: none"> <li>• reduction of electrical power costs</li> <li>• reduction of the effort for processing complaints about the thermal environment</li> </ul>
AI methodology:	<ul style="list-style-type: none"> <li>• Supervised Learning from time series <ul style="list-style-type: none"> <li>○ recurrent neural networks</li> <li>○ 1D Convolutional Networks</li> <li>○ transfer learning</li> <li>○ for comparison: classic statistical methods for time series forecasts</li> </ul> </li> <li>• derive of recommendations: <ul style="list-style-type: none"> <li>○ forecasts for various scenarios</li> <li>○ model-predictive control via black-box-modeling (see above)</li> <li>○ reinforcement learning (dadurch beschränkt, dass Interaktion mit dem echten System praktisch nicht möglich ist)</li> </ul> </li> </ul>

### 9.2.3. Use Case 3 Anforderungen

Title:	Detection of anomalous behavior from monitoring data	UC ID-Nr.:	3
--------	--	------------	---

<p>Description:</p>	<p>Goal of this use-case is to identify datapoints with anomalous behavior (missing or unusual readings) and to present them to the operator for further inspection in timely manner.</p> <p>In regular day-to-day operation, building operators care about the normal operation of the building. Some problems may remain undetected if:</p> <ul style="list-style-type: none"> <li>- the operator does not manually check the specific datapoint state often</li> <li>- there are abnormal changes of values that cannot be detected with preset monitoring dashboards (e.g. too rapid value changes, dashboard not containing the information of interest, monitoring down and latest value held due to the event-based tracking of the specific data point)</li> <li>- Building users do not report problems</li> </ul> <p>Apart from the preset dashboards that usually contain only the current state of monitored variables, there are many more monitoring datapoints that are checked rarely or never, whose behavior may indicate problems before they are manually detected and reported.</p>		
<p>Non-goals:</p>	<p>Detecting reason of anomalous behavior (no diagnosis)</p>		
<p>Stakeholder:</p>	<p>Operator</p>		
		<p>Main actor:</p>	<p>Operator</p>
<p>Pre-conditions:</p>	<p>External data:</p> <ul style="list-style-type: none"> <li>• None</li> </ul> <p>Operational data:</p> <ul style="list-style-type: none"> <li>• sufficient amount of historical monitoring data for training of anomaly detection models</li> <li>• Anomalous events (relevant data points and time/period of event)</li> <li>• milestone from which to check for anomalous or missing readings</li> <li>• in subsequent training it would be useful to be able to incorporate feedback from the operator (false positives and undetected anomalies)</li> </ul>		<p>Process-related information:</p> <ul style="list-style-type: none"> <li>• relationships between datapoints, naming scheme, other available documentation of the control system</li> </ul>
<p>Post-conditions:</p>	<p>Recommendations via AI:</p> <ul style="list-style-type: none"> <li>• Notifications to the operator about detected anomalies with references to specific data points and time/periods of anomalous events</li> </ul>		

	<ul style="list-style-type: none"> <li>• Custom Inspection view with related data points for checking</li> <li>• Feedback from the operator (“Issue”, “non-issue”, “to check”....) to assist in later retraining or calibrating the frequency of notifications/sensitivity of anomaly detection.</li> <li>• System reaction <ul style="list-style-type: none"> <li>○ <b>Issue:</b> The operator confirms that the problem is correctly detected. This information is considered by the system.</li> <li>○ <b>Non-Issue:</b> The feedback goes as input into the system and helps to improve accuracy.</li> <li>○ <b>To Check:</b> This signal means that at the moment it is not possible to determine if it is an anomaly or not. This feedback doesn’t go into the system but is retained for future reference.</li> </ul> </li> </ul>
<p>Process flow:</p>	<ol style="list-style-type: none"> <li>1. Identify normal update periods per datapoint</li> <li>2. Identify common data ranges based on correlations</li> <li>3. Analyze in fixed predefined intervals or from specified point in time</li> <li>4. Identify and display elements/datapoints of interest (anomalies/missing data)</li> <li>5. Dynamically update threshold based on previous data and operator feedback</li> <li>6. Periodical retraining of the model incorporating feedback and known flagged issues</li> </ol>
<p>Benefit:</p>	<p><b>Technical:</b>  Detecting monitoring problems early to prevent legal issues (e.g. missing well water consumption necessary to prove rule compliance), quality of room comfort,</p> <p><b>Economical:</b>  Detecting problems early to prevent costly consequences (predictive maintenance)  Helping operator by reducing manual daily (or more frequent) inspection of important datapoints, saving time and money</p>
<p>AI methodology:</p>	<p>Autoencoders for initial model building, Graphs for encoding datapoint proximity in system/topology/domain contexts.</p>