

PersonAI – User-Centered AI-based energy services built on personal preference models

Berichte aus Energie- und Umweltforschung 65/2026

Wien, 2026

Impressum

Medieninhaber, Verleger und Herausgeber:

Bundesministerium für Innovation, Mobilität und Infrastruktur,
Radetzkystraße 2, 1030 Wien

Verantwortung und Koordination: Abteilung III/3 - Energie und Umwelttechnologien

Leitung: DI (FH) Isabella Warisch

Kontakt zur Mission „Klimaneutrale Stadt“: DIⁱⁿ (FH) Katrin Bolovich

Kontakt zu „Technologien und Innovationen für die klimaneutrale Stadt“: DIⁱⁿ (FH) Isabella Warisch

Autorinnen und Autoren:

Univ.Prof. Mag.phil. Dr.techn. Gerald Schweiger, MA MA PhD, Benjamin Kohl, MSc, Katja Ceplak, MSc, Dipl.-Ing. Dr.techn. Thomas Hirsch, Valerie Kakoschke, BSc, TU Wien

DI Theresa Kohl, MSc DiLT Analytics

DI.in Nora Kirchknopf, DI Roman Stelzer, BSc, Prof.(FH) DI(FH) Peter Klanatsky, Forschung Burgenland

Univ.-Prof.in Dr.in Maria Bertel, Universität Graz

Wien, 2026

Ein Projektbericht gefördert im Rahmen von



Rückmeldungen:

Ihre Überlegungen zu vorliegender Publikation übermitteln Sie bitte an iii3@bmimi.gv.at.

Rechtlicher Hinweis

Dieser Ergebnisbericht wurde von die/der Projektnehmer:in erstellt. Für die Richtigkeit, Vollständigkeit, Aktualität sowie die barrierefreie Gestaltung der Inhalte übernimmt das Bundesministerium für Innovation, Mobilität und Infrastruktur (BMIMI) keine Haftung.

Mit der Übermittlung der Projektbeschreibung bestätigt die/der Projektnehmer:in ausdrücklich, über sämtliche für die Nutzung erforderlichen Rechte – insbesondere Urheberrechte, Leistungsschutzrechte sowie etwaige Persönlichkeitsrechte abgebildeter Personen – am bereitgestellten Bildmaterial zu verfügen.

Die/der Projektnehmer:in räumt dem BMIMI ein unentgeltliches, nicht ausschließliches, zeitlich und örtlich unbeschränktes sowie unwiderrufliches Nutzungsrecht ein, das übermittelte Bildmaterial in allen derzeit bekannten sowie künftig bekannt werdenden Nutzungsarten für Zwecke der Berichterstattung, Dokumentation und Öffentlichkeitsarbeit im Zusammenhang mit der geförderten Maßnahme zu verwenden, insbesondere zur Veröffentlichung in Printmedien, digitalen Medien, Präsentationen und sozialen Netzwerken.

Für den Fall, dass Dritte Ansprüche wegen einer Verletzung von Rechten am übermittelten Bildmaterial gegen das BMIMI geltend machen, verpflichtet sich die/der Projektnehmer:in, das BMIMI vollständig schad- und klaglos zu halten. Dies umfasst insbesondere auch die Kosten einer angemessenen rechtlichen Vertretung sowie etwaige gerichtliche und außergerichtliche Aufwendungen.

Vorbemerkung

Der vorliegende Bericht dokumentiert die Ergebnisse eines Projekts aus dem FTI-Schwerpunkt „Klimaneutrale Stadt“ des Bundesministeriums für Innovation, Mobilität und Infrastruktur (BMIMI) und Klima- und Energiefonds (KLIEN). Im Rahmen dieses Schwerpunkts werden Forschung, Entwicklung und Demonstration von Technologien und Innovationen gefördert, mit dem Ziel, einen essentiellen Beitrag zur Erreichung der Klimaneutralität in Gebäuden, Quartieren und Städten zu liefern. Gleichzeitig wird dazu beigetragen, die Lebens- und Aufenthaltsqualität sowie die wirtschaftliche Standortattraktivität in Österreich zu erhöhen. Hierfür sind die Forschungsprojekte angehalten, einen gesamtheitlichen Ansatz zu verfolgen und im Sinne einer integrierten Planung – wie auch der Berücksichtigung aller relevanten Bereiche wie Energieerzeugung, -speicherung und -verteilung, Berücksichtigung von gebauter Infrastruktur, Mobilität und Digitalisierung – angewandte und bedarfsorientierte Fragestellungen zu adressieren.

Um die Wirkung des FTI-Schwerpunkts „Klimaneutrale Stadt“ zu erhöhen, ist die Verfügbarkeit und Verbreitung von Projektergebnissen ein elementarer Baustein. Durch Begleitmaßnahmen zu den Projekten – wie Kommunikation und Stakeholdermanagement – wird es ermöglicht, dass Projektergebnisse skaliert, multipliziert und „Von der Forschung in die Umsetzung“ begleitet werden. Daher werden alle Projekte nach dem Open Access Prinzip in der Schriftenreihe des BMIMI über die Plattform nachhaltigwirtschaften.at frei zugänglich gemacht. In diesem Sinne wünschen wir allen Interessierten und Anwender:innen eine interessante Lektüre.

Inhalt

Vorbemerkung	4
1 Kurzfassung	6
2 Abstract	9
3 Projektinhalt	12
3.1 Ausgangslage & Projektziele	12
3.1.1 Personal Comfort Models	13
3.1.2 Cohort Comfort Models: Personalisierung mit weniger Daten.....	14
3.1.3 Von der Modellgüte zur Wirkung im Betrieb	14
3.2 Vorgangsweise, Methoden und verwendeten Daten	15
3.2.1 Stakeholderworkshop	16
3.2.2 Empirische Studie	17
3.2.3 Datenaufbereitung	21
3.2.4 Komfortmodelle	22
3.2.5 Auswirkung des Komfortbandes auf den Energieverbrauch.....	24
3.2.6 Replikationsstudie	31
3.3 Bewertung der angewendeten Methoden	32
4 Ergebnisse	34
4.1 Datenaufbereitung.....	34
4.2 Komfortmodelle	36
4.3 Auswirkung des Komfortbandes auf den Energieverbrauch	39
4.3.1 Einhaltung des Komfortbandes ENERGETIKUM	39
4.3.2 Jahresenergieverbrauch ENERGETIKUM	41
4.3.3 Zusammenfassung ENERGETIKUM.....	43
4.3.4 Einhaltung des Komfortbandes LOWERGETIKUM.....	43
4.3.5 Jahresenergieverbrauch LOWERGETIKUM.....	45
4.3.6 Zusammenfassung LOWERGETIKUM	47
4.4 Replikationsstudie.....	48
4.5 Innovationen & Highlights	54
4.6 Einpassung in den Schwerpunkt „Klimaneutrale Stadt“	55
5 Schlussfolgerungen.....	57
6 Ausblick und Empfehlungen	64
Tabellenverzeichnis	66
Abbildungsverzeichnis	67
Literaturverzeichnis	68
Abkürzungen	73
Data Management Plan (DMP)	75

1 Kurzfassung

Motivation und Forschungsfrage

Gebäude verursachen rund 40 % des Endenergieverbrauchs und 36 % der CO₂-Emissionen in der EU (European Commission, 2020). Gleichzeitig verbringen Menschen bis zu 90 % ihrer Zeit in Innenräumen (Brasche et al., 2005; Klepeis et al., 2001), deren Qualität Gesundheit, Wohlbefinden und Leistungsfähigkeit beeinflusst (Melikov, 2015; Awada et al., 2021; Crook & Burton, 2010; Wargocki et al., 2019). Der Gebäudebetrieb steht damit vor einer doppelten Herausforderung: Energieverbrauch und Emissionen senken, ohne den Komfort der Nutzer:innen zu beeinträchtigen. Gängige Komfortstandards wie PMV basieren auf Laborstudien und zielen auf das durchschnittliche Empfinden einer Gruppe, bilden individuelle Unterschiede aber nur unzureichend ab. Das Projekt PersonAI untersuchte, ob datengetriebene, personalisierte Komfortmodelle diesen Widerspruch auflösen können und welche Auswirkungen eine kohortenbasierte Temperaturregelung auf Komfort und Energieverbrauch im realen Gebäudebetrieb hat.

Ausgangssituation

Personal Comfort Models (PCM) nutzen subjektives Feedback, physiologische Signale und Umgebungsdaten, um thermische Präferenzen individuell vorherzusagen. Die bisherige Forschung zu PCMs war jedoch überwiegend auf tropische Klimazonen und kontrollierte Laborsettings mit kleinen Stichproben beschränkt. Cohort Comfort Models (CCM) erweitern den Ansatz, indem sie Personen mit ähnlichem Komfortempfinden zu Gruppen zusammenfassen, was eine Personalisierung auch für neue Nutzer:innen mit wenigen Daten ermöglicht. Ob diese Ansätze unter realen Bedingungen in einer europäischen Klimazone funktionieren und welchen Effekt sie im Gebäudebetrieb tatsächlich erzielen, war bisher nicht untersucht.

Projekthalte und Zielsetzungen

PersonAI verfolgte vier Schwerpunkte: die Definition von Anforderungen und Use Cases für nutzer:innenzentrierte Energieservices gemeinsam mit Stakeholdern, die Durchführung einer empirischen Langzeitstudie zur Erhebung von Komfortdaten unter Alltagsbedingungen, die Entwicklung und Erprobung von Cohort Comfort Models mit anschließendem Proof of Concept in einem realen Gebäude sowie ein offenes, datenschutzkonformes Forschungsdatenmanagement.

Methodische Vorgehensweise

Die empirische Studie wurde mit 83 Teilnehmer:innen über vier Wochen im Frühling 2025 durchgeführt. Die Datenerhebung kombinierte Ecological Momentary Assessment (sieben Right-Here-

Right-Now-Befragungen pro Tag über die Cozie-App auf der Apple Watch), physiologische Messungen (Herzfrequenz über Apple Watch und Oura Ring) und Umgebungsdaten (Temperatur, Luftfeuchte, CO₂ über stationäre AirCO2ntrol-Sensoren). Ergänzend wurden im Rahmen eines Onboardings demografische, psychologische und persönlichkeitsbezogene Merkmale erhoben. Nach der Datenaufbereitung umfasste der finale Datensatz 72 Personen. Für die Komfortmodellierung wurde die publizierte Codebasis der Cohort Comfort Models nach Quintana et al. (2023) übernommen und an den eigenen Datensatz angepasst. Aus den gebildeten Kohorten wurden deskriptiv Temperatur-Sollwerte und Komfortbänder abgeleitet, die im Proof of Concept in den Living Labs des Projektpartners Forschung Burgenland als Setpoints eingesetzt wurden. Die energetischen Auswirkungen wurden über Simulationen mit einem datengetriebenen modellprädiktiven Regelungsansatz (DMPC) an zwei Gebäuden mit unterschiedlicher Bauweise und Anlagentechnik bewertet.

Ergebnisse und Schlussfolgerungen

Die Komfortantworten waren stark unbalanciert. Die Klasse „Keine Veränderung“ dominierte bei den meisten Teilnehmer:innen. Die trainierten Komfortmodelle konnten die selteneren Klassen „Kühler“ und „Wärmer“ nicht zuverlässig erkennen. Im Proof of Concept zeigte die kohortenbasierte Temperatursteuerung keinen eindeutigen Komfort-Effekt. Auch bei bewusst falscher Kohortenzuordnung wurde ein vergleichbarer Zufriedenheitsanstieg beobachtet.

Eine im Anschluss an das PoC durchgeführte Reproduktionsstudie auf den Originaldaten (Dorn-Datensatz) und dem PersonAI-Datensatz identifizierte mehrere methodische Punkte in der Referenz-Codebasis. Die Evaluierungsstrategie wurde durch eine personenbezogene Leave-One-Out-Cross-Validation ersetzt, die bei kleinen Datensätzen verzerrungsärmere Schätzungen liefert und in der Feature-Selektion wurde ein Information Leak behoben. Die im Original verwendete Bewertungsmetrik F1-Micro wurde um F1-Macro ergänzt, das die Klassifikationsleistung über alle drei Komfortklassen gleichmäßig gewichtet. F1-Macro zeigt, dass die unter F1-Micro scheinbar gute Leistung der Modelle im Wesentlichen auf der korrekten Vorhersage der dominanten Klasse „Keine Veränderung“ beruht. Auch auf dem umfangreicheren Referenzdatensatz ließ sich kein statistisch belastbarer Leistungsunterschied zwischen den CCM und einer einfachen Baseline feststellen. Der Vergleich von korrekter und absichtlich falscher Kohortenzuordnung ergab zudem, dass die berichteten Leistungsgewinne auf wenige Ausreißer mit nahezu homogenem Antwortverhalten zurückgehen. Die Annahme, dass 60 Datenpunkte pro Person für stabile Komfortvorhersagen ausreichen, konnte ebenfalls nicht bestätigt werden.

Die parallel durchgeführten Energiesimulationen zeigen hingegen, dass breitere Komfortkorridore in Kombination mit modellprädiktiver Regelung erhebliches Einsparpotenzial bieten. Am ENERGETIKUM, einem Gebäude mit regelbarer Verschattung und thermisch aktivierten Bauteilsystemen, reduzierte der DMPC den Heizenergiebedarf um bis zu 47 % und den elektrischen Energiebedarf der Wärmepumpe um bis zu 45 % gegenüber einem konventionellen Zweipunktreger. Am LOWENERGETIKUM, einem Gebäude ohne regelbare Verschattung, fielen die Einsparungen mit 7 bis 8 %

geringer aus. Die Einsparungen resultieren primär aus der prädiktiven Regelungsstrategie und den damit erschlossenen thermischen Freiheitsgraden, nicht aus der Personalisierung der Komfortmodelle.

Ausblick

Die Projektergebnisse werden in mehreren Anschlussprojekten weiterverfolgt. Im Projekt WellFit wird das Studiendesign bei sommerlichen Temperaturen repliziert und erweitert. In weiteren geplanten Vorhaben soll die Verbindung von Innenraumluftqualität, Wearable-Daten und KI-gestützter Auswertung vertieft werden. Die Reproduktionsstudie wird als eigenständige wissenschaftliche Publikation veröffentlicht. Für die energetische Seite wird empfohlen, Komfortbänder zukünftig nicht nur als feste Randbedingung, sondern als eigenständigen Optimierungsparameter zu betrachten und deren Wirkung gebäudespezifisch, unter Berücksichtigung von Bauweise, Speichermasse, Verschattung und verfügbarer Anlagentechnik, zu bewerten.

2 Abstract

Motivation and research question

Buildings account for around 40 % of final energy consumption and 36 % of CO₂ emissions in the EU (European Commission, 2020). At the same time, people spend up to 90% of their lives indoors (Brasche et al., 2005; Klepeis et al., 2001), where environmental quality affects health, well-being and productivity (Melikov, 2015; Awada et al., 2021; Crook & Burton, 2010; Wargocki et al., 2019). Building operations therefore face a dual challenge: reducing energy consumption and emissions without compromising occupant comfort. Established comfort standards such as PMV are based on laboratory studies and target the average thermal perception of a group, but fail to capture individual differences adequately. The PersonAI project investigated whether data-driven, personalised comfort models can resolve this tension and what effects a cohort-based temperature control strategy has on comfort and energy consumption under real building operating conditions.

Initial situation / status quo

Personal Comfort Models (PCM) use subjective feedback, physiological signals and environmental data to predict individual thermal preferences. However, previous PCM research has been largely limited to tropical climates and controlled laboratory settings with small sample sizes. Cohort Comfort Models (CCM) extend this approach by grouping occupants with similar comfort profiles, enabling personalisation even for new users with little or no historical data. Whether these approaches work under real-world conditions in a European climate zone, and what effect they actually achieve in building operations, had not been investigated prior to this project.

Project contents and objectives

PersonAI pursued four main objectives: defining requirements and use cases for user-centered energy services together with stakeholders, conducting an empirical longitudinal study to collect comfort data under everyday conditions, developing and testing Cohort Comfort Models with a subsequent proof of concept in a real building, and implementing open, privacy-compliant research data management.

Methodical procedure

The empirical study was conducted with 83 participants over four weeks in spring 2025. Data collection combined Ecological Momentary Assessment (seven Right-Here-Right-Now surveys per day via the Cozie app on the Apple Watch), physiological measurements (heart rate via Apple Watch and Oura Ring) and environmental data (temperature, humidity, CO₂ via stationary AirCO2ntrol sensors).

In addition, demographic, psychological and personality-related characteristics were collected through an onboarding survey. After data preparation, the final dataset comprised 72 participants. For comfort modelling, the published Cohort Comfort Models codebase by Quintana et al. (2023) was adopted and adapted to the project's own dataset. Temperature setpoints and comfort bands were derived descriptively from the resulting cohorts and deployed as setpoints in the proof of concept at the Living Labs of project partner Forschung Burgenland. The energy implications were evaluated through simulations using a data-driven model predictive control approach (DMPC) on two buildings with different construction types and technical equipment.

Results and conclusions

The comfort responses were highly imbalanced. The class "No Change" dominated for most participants. The trained comfort models were unable to reliably identify the less frequent classes "Cooler" and "Warmer". In the proof of concept, the cohort-based temperature control showed no clear comfort effect. A comparable increase in satisfaction was observed even for participants deliberately assigned to the wrong cohort.

A replication study conducted after the PoC on both the original data (Dorn dataset) and the PersonAI dataset identified methodological issues in the reference codebase. The evaluation strategy was replaced by a person-level Leave-One-Out Cross-Validation, which provides less biased estimates for small datasets and an information leak in the feature selection was corrected. The original evaluation metric F1-Micro was supplemented with F1-Macro, which weights classification performance equally across all three comfort classes. F1-Macro reveals that the seemingly good performance under F1-Micro is largely attributable to correct prediction of the dominant class "No Change". Even on the more extensive reference dataset, no statistically robust performance difference between CCMs and a simple baseline could be established. A comparison of correct and deliberately incorrect cohort assignments further showed that the reported performance gains are driven by a small number of outliers with near-homogeneous response patterns. The assumption that 60 data points per person are sufficient for stable comfort predictions could likewise not be confirmed.

The energy simulations conducted in parallel show, however, that wider comfort corridors in combination with model predictive control offer considerable savings potential. At the ENERGETIKUM, a building with controllable shading and thermally activated building systems, DMPC reduced heating energy demand by up to 47 % and the electrical energy demand of the heat pump by up to 45 % compared to a conventional two-point controller. At the LOWERGETIKUM, a building without controllable shading, savings were more modest at 7 to 8 %. The energy savings result primarily from the predictive control strategy and the thermal degrees of freedom it exploits, not from the personalisation of the comfort models.

Outlook

The project results are being pursued in several follow-up projects. The WellFit project replicates and extends the study design under summer conditions. Further planned projects aim to deepen the connection between indoor air quality, wearable data and AI-based analysis. The replication study will be published as an independent scientific paper. On the energy side, it is recommended that comfort bands should in future be treated not only as fixed constraints but as independent optimisation parameters, and that their effects should be evaluated on a building-specific basis, taking into account construction type, thermal mass, shading and available building services.

3 Projekinhalt

3.1 Ausgangslage & Projektziele

Gebäude verursachen rund 40 % des Endenergieverbrauchs und 36 % der CO₂-Emissionen in der EU und stehen damit im Fokus aller Klimaschutzbemühungen (European Commission, 2020). Weil Menschen bis zu 90 % ihres Lebens in Innenräumen verbringen (Brasche et al., 2005; Klepeis et al., 2001), kommt dem Innenraumklima eine zentrale Rolle für Gesundheit, Wohlbefinden und Krankheitsprävention zu (Awada et al., 2021; Crook & Burton, 2010; Melikov, 2015; Wargocki et al., 2019). Dieser doppelte Anspruch führt zu einer zentralen Herausforderung: Gebäude müssen Emissionen und Energieverbrauch deutlich senken und zugleich Innenräume so bereitstellen, dass sie Gesundheit, Komfort und Leistungsfähigkeit unterstützen. Die Entwicklung intelligenter Energieservices auf Basis von IoT und Künstlicher Intelligenz könnte eine Schlüsselrolle spielen, um diese Ziele zu erreichen. Dazu gehören prädiktive Regelung, Demand-Side-Management, Prognosen, automatische Fehlerdiagnose und -prävention sowie neue Betriebsweisen, die erneuerbare Energien und Gebäudeflexibilität integrieren (Drgoňa et al., 2020; Merabet et al., 2021; Vasquez-Canteli & Nagy, 2019; Seremeti & Kougias, 2021; Shi & O'Brien, 2019).

In der Praxis werden HVAC-Systeme jedoch häufig über starre Raumtemperatursollwerte betrieben. Falsch gewählte Sollwerte, Übersteuerung oder konservative Sicherheitszuschläge führen nicht selten zu ineffizientem Betrieb, höherem Energieeinsatz und dennoch unzureichendem Komfort (Han et al., 2019; Ngarambe et al., 2020). Normative Behaglichkeitsdefinitionen und Standardmodelle dienen als Planungs- und Betriebsgrundlage, bilden aber die Vielfalt realer Bedürfnisse nur eingeschränkt ab. Maßnahmen wie pauschale Temperatursenkungen in Büros stoßen ohne Nutzerakzeptanz auf Widerstände (Rohrhofer, 2022; vienna.at, 2022). Aktuelle Forschung unterstreicht, dass der Mensch ins Zentrum von Energieservices rücken muss – nicht nur als Lastgröße, sondern als aktive:r Nutzer:in mit Präferenzen, Feedback und Rechten (O'Brien et al., 2020; Schweiger et al., 2020). In diesem Kontext wird deutlich: **Der Gebäudebetrieb der Zukunft muss digital, datenbasiert und zugleich menschenzentriert sein.**

Gängige Komfortstandards, wie ISO 7730:2005, ASHRAE 55-2020 und EN 16798-1:2019 (ASHRAE, 2020; CEN, 2019; ISO, 2005), stützen sich auf Laborstudien und zielen auf ein „durchschnittliches“ Komfortempfinden einer größeren Gruppe. Sie setzen zum Teil Größen voraus, die im Betrieb schwer oder nur indirekt erfassbar sind (z.B. Bekleidung, Stoffwechselrate), und sie generalisieren über Bevölkerungsgruppen und Nutzungssituationen hinweg (Dentel & Dietrich, 2006; Kim et al., 2018; Tartarini et al., 2022; Xie et al., 2020). In der Folge sind die Modelle für reale Gebäudeanwendungen – in denen Alter, Geschlecht, Aktivität, Bekleidung, Gesundheit und situative Faktoren variieren – häufig ungenau, insbesondere wenn es um individuelle Vorhersagen und eine dynamische Regelung geht (Kim et al., 2018; Tartarini et al., 2022; Xie et al., 2020). Ihre Übertragbarkeit auf

Kinder, ältere Menschen oder Personen mit Vorerkrankungen kann begrenzt sein, dennoch prägen sie Planung und Betrieb, etwa auch in Schulen (Ngarambe et al., 2020).

Diese Diskrepanz zwischen normierter Durchschnittsannahme und individueller Realität wirkt sich doppelt nachteilig aus. Zum einen steigt das Risiko, dass der reale Komfort nicht verbessert wird, obwohl Anlagen aufwendig dimensioniert und konservativ betrieben werden. Zum anderen drohen ineffiziente Betriebsweisen, die Energieverbrauch und Kosten erhöhen, ohne die Zufriedenheit der Nutzer:innen verlässlich zu steigern. Forschungsarbeiten verweisen zusätzlich darauf, dass standardisierte Ansätze dynamische, alltagsnahe Faktoren – etwa wechselnde Aktivitätsgrade, zeitabhängige Präferenzen oder mikroklimatische Unterschiede – nicht angemessen berücksichtigen (Han et al., 2019; Ngarambe et al., 2020; Kim et al., 2018; Tartarini et al., 2022; Xie et al., 2020). Daraus folgt ein doppelter Wandel: Zum einen braucht es den Schritt von statischen Gruppenmodellen zu personalisierten, datengetriebenen Komfortvorhersagen, die technisch in Gebäude eingebettet werden können. Zum anderen verändert sich die Rolle der Nutzer:innen – weg von der passiven Konsument:innenperspektive (Devine-Wright & Devine-Wright, 2005) hin zu aktiver Beteiligung, die durch soziale Akzeptanz und digitale Technologien gestützt wird (Hampl et al., 2022; Hargreaves et al., 2010; Schweiger et al., 2020). User-zentrierte Energieservices ermöglichen diese aktive Mitgestaltung und Datennutzung. Deren Rückmeldungen und Präferenzen fließen in Regelstrategien ein und verbessern so Komfort wie Effizienz (O'Brien et al., 2020; Schweiger et al., 2020). Das erhöht die Akzeptanz neuer Technologien und stärkt die Wirkung von Effizienzmaßnahmen, insbesondere wenn genderspezifische und andere Diversity-Aspekte systematisch berücksichtigt werden (World Economic Forum, 2020; Simonite, 2018; Perrault et al., 2019; Eveleth, 2014; Boyd, 2014; Bernabeu, 2017; Niethammer, 2020).

3.1.1 Personal Comfort Models

Personal Comfort Models (PCM) sind individuelle, datengetriebene Modelle zur Vorhersage thermischer Präferenzen. Sie kombinieren subjektives Feedback (z. B. „wärmer/kälter/keine Änderung“, Zuglufterleben, Bekleidungsfaktoren, Aktivitätsgrad) mit physiologischen Signalen (Hauttemperatur, Herzfrequenz, Schritte) und Umgebungsparametern (Luft- und Strahlungstemperatur, Feuchte, Luftbewegung), ergänzt um kontextuelle Informationen (Ort, Tageszeit, Tätigkeit) (Arakawa Martins et al., 2022; Kim et al., 2018; Tartarini et al., 2022). Fortschritte bei Wearables und IoT-Sensorik – von Smartwatches bis zu stationären und tragbaren Luftqualitätssensoren – erleichtern heute die Erhebung solcher Daten im Alltag. Erste Feldstudien zeigen, dass physiologische Messwerte, insbesondere Haut- und Near-Body-Temperaturen sowie Herzfrequenz, die Vorhersage thermischer Präferenzen substanziell verbessern können (Merabet et al., 2021; Tartarini et al., 2022).

Die Entwicklung belastbarer PCMs stellt jedoch hohe Anforderungen an Studiendesign, Datenerhebung und maschinelles Lernen. Langfristige, alltagsnahe Datensammlungen mit wiederholten Kurzbefragungen („Right-Here-Right-Now“-Surveys) sind aufwendig und erfordern Motivation und Bindung der Teilnehmenden über Wochen oder Monate (O'Brien et al., 2020; Tartarini et al., 2022). Viele bisherige Studien waren auf Büros oder Labore begrenzt, häufig in tropischen Klimazonen, mit

kleinen Stichproben (Arakawa Martins et al., 2022; Nazarian et al., 2021). Das erschwert die Generalisierung auf europäische Klimazonen, vielfältige Gebäudetypen sowie unterschiedliche Bevölkerungsgruppen bezüglich Alter, Geschlecht, BMI oder Gesundheitszustand (Arakawa Martins et al., 2022; Nazarian et al., 2021; Stopps et al., 2021). Saisonale Effekte und sich verändernde Präferenzen bleiben bei kurzen Erhebungen unterbelichtet. Hinweise auf geschlechtsspezifische Unterschiede in der thermischen Komfortwahrnehmung sind vorhanden, fallen in der Literatur jedoch nicht durchgängig gleich aus und sollten daher in repräsentativen Datensätzen weiter untersucht werden (Zeshan et al., 2022). Fragen zu Gender-Bias und Diversity im Kontext datengetriebener Systeme unterstreichen zusätzlich die Notwendigkeit, solche Unterschiede systematisch zu berücksichtigen (Boyd, 2014; Bernabeu, 2017; Eveleth, 2014; Niethammer, 2020; Perrault et al., 2019; Simonite, 2018; World Economic Forum, 2020). Auch die Modellierungspipeline selbst bedarf einer sorgfältigen Standardisierung. Unterschiedliche Feature-Sets, uneinheitliche Validierungsverfahren und teils intransparente Prozesse erschweren Vergleichbarkeit und Reproduzierbarkeit (Arakawa Martins et al., 2022; Stopps et al., 2021; Tartarini et al., 2022). Häufig verwendete Verfahren wie Random Forest sind zwar leistungsfähig, aber daten- und rechenintensiv; zugleich bilden einige Ansätze ordinale Präferenzskalen nicht adäquat ab und reagieren instabil in einer Echtzeitregelung (Tartarini et al., 2022). Hier bieten physics-informed Machine Learning und Transfer Learning vielversprechende Ansätze: Indem Vorwissen über thermische Prozesse einfließt oder vortrainierte Wissensbasen wiederverwendet werden, lassen sich Trainingsdaten verringern, Modelle beschleunigen und Interpretierbarkeit erhöhen (Park & Park, 2022). Insgesamt geht es darum, Genauigkeit, Robustheit, Rechenaufwand und Transparenz so auszubalancieren, dass sich PCMs in praktische, sichere und datenschutzkonforme Energieservices überführen lassen.

3.1.2 Cohort Comfort Models: Personalisierung mit weniger Daten

Neben individuell trainierten PCMs werden Cohort Comfort Models (CCM) diskutiert, die Ähnlichkeiten zwischen Personen nutzen, um Präferenzen für neue Nutzer:innen mit wenig oder keinen historischen Daten zu schätzen (Quintana et al., 2023). CCMs versprechen, Personalisierung und Dateneffizienz zu verbinden – ein entscheidender Vorteil, wenn Skalierbarkeit und frühe Nützlichkeit im Vordergrund stehen. Damit CCMs Entscheidungen in Planung und Betrieb verlässlich unterstützen, brauchen ihre empirischen Befunde jedoch unabhängige Replikationen. Methodik, Generalisierbarkeit, mögliche Verzerrungen und die Stabilität unter unterschiedlichen Datenbedingungen müssen geprüft und standardisiert bewertet werden. In der Literatur wird daher eine mehrstufige Validierung gefordert, die sowohl das experimentelle Setup als auch Replikationen auf Original- und neuen Datensätzen umfasst, inklusive sauberer ML-Protokolle und Bias-Analysen.

3.1.3 Von der Modellgüte zur Wirkung im Betrieb

Die bisherige Forschung fokussierte häufig auf die Vorhersagegüte von Komfortmodellen. Weniger systematisch quantifiziert ist der daraus tatsächlich erzielbare Mehrwert im Gebäudebetrieb – etwa Einsparungen bei Energie und Kosten oder belastbare Komfortverbesserungen unter realen Bedin-

gungen (Ngarambe et al., 2020). Dabei zeigen Studien zu KI-gestützten Energieservices bereits erhebliche Potenziale: Model Predictive Control kann den Energieverbrauch um bis zu 28 % reduzieren (Drgoňa et al., 2020), automatische Fehlererkennung erreicht in gewerblichen Gebäuden Einsparungen von 15–30 % und verbessert gleichzeitig das Innenraumklima (Shi & O’Brien, 2019). Simulationen und erste Feldarbeiten deuten darauf hin, dass die Kombination aus PCM und solchen Services sowohl den Komfort deutlich steigern als auch den Energieeinsatz spürbar senken kann; Abschätzungen reichen von 21,81 % bis 44,36 % Energieeinsparung und 21,67 % bis 85,77 % Komfortverbesserung (Merabet et al., 2021). Was bisher fehlt, ist der Schritt von der simulierten Modellgüte zur nachgewiesenen Wirkung unter realen Bedingungen, einschließlich der Einbindung tragbarer Sensorik und einer Human-in-the-Loop-Regelung in der Gebäudeautomation (Jung & Jazizadeh, 2019; Merabet et al., 2021).

Diese Fragen waren der Ausgangspunkt für das Projekt PersonAI. Das Projekt verfolgte das Ziel, user-zentrierte Energieservices zu entwickeln und zu validieren, die mithilfe von Cohort-Ansätzen individuelle Komfortbedürfnisse mit Energieeffizienz verbinden. Im Einzelnen umfasste das vier Arbeitsschwerpunkte. Zunächst sollten gemeinsam mit relevanten Stakeholdern die Anforderungen, Use Cases und rechtlichen Rahmenbedingungen für user-zentrierte Energieservices definiert werden. Darauf aufbauend war eine empirische Langzeitstudie mit einem repräsentativen Teilnehmer:innenmix geplant, um auf Basis von Wearable-Daten, Umgebungssensoren und wiederholten Komfortbefragungen robuste Personal und Cohort Comfort Models zu entwickeln. Die so trainierten Modelle sollten in einem Proof of Concept in einer realen Testumgebung erprobt werden, um erstmals die Auswirkungen einer kohortenbasierten Komfortsteuerung auf Zufriedenheit und Energieverbrauch unter Alltagsbedingungen zu quantifizieren.

3.2 Vorgangsweise, Methoden und verwendeten Daten

Die methodische Umsetzung des Projekts gliedert sich in fünf Abschnitte. Kapitel 3.2.2 und 3.2.2 beschreiben den Stakeholderworkshop, das Studiendesign und die Durchführung der empirischen Erhebung. Kapitel 3.2.3 dokumentiert die Aufbereitung und Zusammenführung der Datenquellen. Kapitel 3.2.4 erläutert die Komfortmodellierung nach dem Cohort-Comfort-Models-Ansatz, die Ableitung der Komfortbänder und das Setup des Proof of Concept. In Kapitel 3.2.5 wird die Methodik der Energiesimulationen dargestellt, mit der die Auswirkung der Komfortbänder auf den Gebäudeenergieverbrauch untersucht wurde. Kapitel 3.2.6 beschreibt die nach Abschluss des PoC durchgeführte Reproduktionsstudie, in der die zugrunde liegende Modellierungs-Pipeline einer methodischen Überprüfung unterzogen wurde.

3.2.1 Stakeholderworkshop

Im Rahmen des Projekts fand am 25.04.2024 ein interaktiver Online-Workshop statt. Es nahmen rund 30 Expert:innen aus ganz Österreich teil. Workshopprogramm und Inhalte sind auf der Einladung ersichtlich. Das Workshopkonzept wurde auf Basis ausgiebiger Literaturrecherche bzgl. potentiellen Use Cases mit besonderem Augenmerk auf die technische Umsetzung, Privacy, Security und Datenschutz sowie auf Maßnahmen in Zusammenhang mit der Bildung von "Technologievertrauen" gelegt. Zu jedem Themenblock (siehe Screenshot Einladung in Abbildung 1) wurden Menti-meter-Umfragen und Miro-Boards für die interaktive Bearbeitung durch die Teilnehmer:innen gestaltet, um Feedback zu den Fallstudien, technischen und rechtlichen Herausforderungen abzuholen sowie den Forschungsbedarf weiter zu definieren.



Einladung zum Online-Workshop

„Get your own personal comfort zone!“

Optimierter Gebäudebetrieb durch Nutzer:innenfeedback

**25. April 2024
14:30-16:00 Uhr**

Die durchschnittliche Bevölkerung verbringt **90 % ihrer Zeit in Gebäuden**. Das Innenraumklima hat großen Einfluss auf **Wohlbefinden und Gesundheit**, wobei individueller Komfort stark von Alter, Geschlecht oder Gesundheitszustand abhängen.

Die **Beheizung, Kühlung und Lüftung von Gebäuden** erfolgt üblicherweise im Rahmen von etablierten, allgemein festgelegten Sollwerten für Temperatur, Luftfeuchtigkeit oder CO₂. Diese wurden entweder in der Planungs- und Inbetriebnahmephase definiert oder im laufenden Betrieb durch Nutzer:innenrückmeldungen angepasst.

Im Spagat zwischen **Nutzer:innenzufriedenheit und energieeffizienten Gebäuden** könnten innovative Konzepte wie Feedbackmechanismen über Smartwatches oder persönliche Komfortsysteme wie einzeln beheizbare Arbeitsplätze Anwendung finden. Das **FFG-Projekt PersonAI** will den Mehrwert und die Praxistauglichkeit dieser Systeme mit Gebäudebetreiber:innen, -eigentümer:innen und Nutzer:innen erforschen.

Wir laden Sie ein, sich mit uns über die Potentiale neuartiger Konzepte und Ihre Praxiserfahrungen in einem kostenlosen Online-Workshop auszutauschen!

Interaktives Programm (14:30-16:00 Uhr)

1. **Begrüßung und Einleitung**
2. **Thermischer Komfort, Gesundheit und Nutzer:innenfeedback in Gebäuden**
 - Überblick zu unterschiedlichen Kriterien und Bewertungskonzepten wie ÖNORM B 8110-3 oder PMV
 - Monitoring: Vom Planungsstandard in die Gebäudebetriebsphase
 - Fallbeispiele aus der Praxis: Direkte Einbindung von Nutzer:innenfeedback in die Gebäuderegelung
3. **Gebäudekonditionierung auf Basis von individuellen Komfortpräferenzen**
 - Persönliche Komfortmodelle durch Smartwatches
 - Fallbeispiele aus aller Welt: individuelle Komfortsysteme in Büros, Schulen, Krankenhäusern oder Pflegeheimen
4. **Abschluss und Ausblick**

Wir bitten um Anmeldung bis zum 23. April 2024 über das [Anmeldeformular](#).

Logos: TU Graz, DiLT Analytics, FORSCHUNG Burgenland, UNI Graz, green energy lab, FFG

Der Workshop wird im Rahmen des FFG-Forschungsprojekts **PersonAI** gemeinsam von der Technischen Universität Graz, FORSCHUNG Burgenland, Universität Graz, DiLT Analytics und dem Green Energy Lab durchgeführt.

Abbildung 1: Einladung zum Workshop am 25. April 2024 © DiLT Analytics

Die Ergebnisse des Expert:innenworkshops stimmen mit den Praxiserfahrungen des Konsortiums überein. Dabei wurde deutlich, dass die Nutzer:innenzufriedenheit im Gebäudebetrieb häufig nicht systematisch erfasst wird. Vielmehr erfolgt eine Evaluation meist nur anlassbezogen, beispielsweise bei Beschwerden. Lediglich weniger als 20 % der Workshopteilnehmenden gaben an, Nutzer:innenfeedback aktiv zur Betriebsoptimierung einzusetzen. Für die erfolgreiche Integration persönlicher Komfortmodelle in den Gebäudebetrieb ist daher entscheidend, dass innovative technische Konzepte einfach implementierbar und wartungsarm sind. Einzelgeräte wie Klimastühle, beheizbare Schreibtische, Fußwärmer oder Tischventilatoren werden aufgrund des potenziellen Wartungsaufwands kritisch bewertet.

3.2.2 Empirische Studie

3.2.2.1 Studiendesign

Ziel war die Erhebung robuster, übertragbarer Daten für Personal und Cohort Comfort Models (PCM/CCM) unter realen Alltagsbedingungen. Dazu kombinierten wir Ecological Momentary Assessment (EMA) in Form von Right-Here-Right-Now Abfragen (RHRN) mit Wearables und stationären sowie tragbaren Umweltsensoren. RHRN ermöglichten kurzformatige Abfragen im Alltag und verknüpften subjektive Präferenzen, Stimmung, interozeptive Aspekte und physiologische Reaktionen mit objektiven Messungen der Innenraumluftqualität (IAQ). Relevante IAQ-Parameter umfassten Temperatur, relative Feuchte, Luftdruck und Schadstoffe (ASHRAE, 2020; ASHRAE, 2022; Awada et al., 2021; Seguel et al., 2016; Wargocki et al., 2019).

Die Datenerhebung erstreckte sich über vier Wochen und umfasste subjektive, physiologische und umweltbezogene Daten. Abbildung 2 gibt einen Überblick über die Methodik. Die Studie wurde von der Ethikkommission der Technischen Universität Graz, Österreich, genehmigt (GZ: EK-35/2024). Als Aufwandsentschädigung durften die Teilnehmenden die verwendeten Apple Watches behalten.

Daten der Teilnehmer:innen

1. Einführungsbefragung

- Demografische Daten
- Wärme- und Kältetoleranz
- Interozeption
- Psychische Gesundheit und physiologische Symptome
- Persönlichkeit
- Bewertung der Lebensqualität

1. Ecological Momentary Assessment (EMA)

- Temperaturpräferenz
- Stimmung
- Wahrnehmung des Herzschlags
- Standort
- Aktivitätsniveau in den letzten 10 Minuten



Abbildung 2: Abbildung der Vorgehensweise der Datenerhebung mit verwendeten Geräten, Fragebögen und Surveys © DiLT Analytics

3.2.2.2 Teilnehmende und Rekrutierung

Rekrutiert wurde über soziale Medien und Mundpropaganda. Die Einschlusskriterien beinhalteten Personen, die zwischen 18 und 65 Jahre alt waren, beruflich in einem Bürossetting tätig waren und ein iPhone mit mind. iOS 17 besaßen, welches eine Apple Watch Series 9 oder 10 (Apple Inc., Kalifornien, USA) unterstützt. Ausschlusskriterien waren: chronische Erkrankungen oder Medikation, die Luftqualitätswahrnehmung oder Thermoregulation beeinflussen könnten. Offengelegte Vorerkrankungen/Medikationen wurden fallweise beurteilt. Insgesamt nahmen 83 Personen an der Studie teil (siehe Foto einer Infoveranstaltung in Abbildung 3).



Abbildung 3: Informationsveranstaltung für Teilnehmer:innen © DiLT Analytics

3.2.2.3 Erhebungsinstrumente

Während der vierwöchigen Erhebungsphase wurden die Teilnehmer:innen mit mehreren Geräten ausgestattet. Eingesetzt wurde die Apple Watch Series 9 und 10, die mit den iPhones der Teilnehmer:innen gekoppelt wurde. Die Cozie-App (Tartarini et al., 2023) präsentierte EMA-Fragen direkt auf der Uhr und erfasste Herzfrequenzdaten (HR). Tragezeit war täglich 08:00–20:00 Uhr während der RHRN-Fenster. Zusätzlich trugen die Teilnehmenden den Oura Ring Gen4 (Oura Health Oy, Oulu, Finnland), siehe Abbildung 4. Die Oura-App wurde auf den privaten Smartphones installiert. Der Ring sollte möglichst durchgängig (Tag/Nacht) getragen werden, mit freiwilliger Abnahme bei Unbehagen in der Nacht. Die Oura App-Funktionen waren voll zugänglich. HR-Daten flossen primär in die Komfortmodellierung ein. Pro Person wurden zwei AirCO2ntrol 5000 (TFA Dostmann GmbH & Co. KG, Wertheim, Deutschland) bereitgestellt, die Temperatur, relative Feuchte und CO₂ in 5-Sekunden-Intervallen messen. Ein Sensor wurde am Arbeitsplatz (Schreibtisch), der andere zu Hause im gewöhnlichen Aufenthaltsraum platziert. Die Teilnehmer:innen wurden instruiert direkte Sonneneinstrahlung auf die Geräte zu vermeiden.



Abbildung 4: Eingesetzte Geräte - iPhone, Oura Ring und Apple Watch mit Cozie-App © TU Wien

3.2.2.4 Subjektive Erhebungen

Während der Studie wurden täglich sieben RHRN-Prompts in 105-Minuten-Intervallen zwischen 08:00 und 20:00 Uhr präsentiert (insgesamt 196 RHRN). Beantwortung erfolgte auf der Apple Watch via der Cozie App (Tartarini et al., 2023).

Erfasst wurden:

- momentane thermische Präferenz (kühler/keine Änderung/wärmer),
- aktuelle Stimmung (gut/neutral/schlecht),
- Herzschlagwahrnehmung (sehr stark/stark/mittel/schwach/gar nicht (nach Walentynowic et al., 2023),
- Aufenthaltsort (zu Hause/bei der Arbeit/unterwegs) und
- Aktivität der letzten 10 Minuten (körperliche Aktivität/Schreibtischarbeit/ Entspannung/anderes)

Die Fragen wurden immer in derselben Reihenfolge präsentiert (siehe Abbildung 5) Verpasste Abfragen konnten manuell nachgeholt werden. Für die Kompensation waren mindestens 147 beantwortete RHRNs (75 %) erforderlich.

Zusätzlich wurden im Rahmen der Onboarding-Umfrage demografische Angaben, Hitze- und Kältetoleranz, Körperwahrnehmung (MAIA-2; Mehling et al., 2018), psychische Gesundheit und Symptome

(BSI; Derogatis, 1975), Persönlichkeit (BFI-2-S; Soto & John, 2017), sowie Lebenszufriedenheit (SWLS; Diener et al., 1985) mittels Fragebögen erhoben. Diese Konstrukte wurden inkludiert, um die allgemeinen persönlichen Vorlieben, die Persönlichkeitsstruktur sowie den mentalen und körperlichen Zustand der Teilnehmer:innen zu erfassen, die sich auf die Empfindungen und Wahrnehmungen der Umgebung auswirken könnten.



Abbildung 5: Ein Ausschnitt aus den RHRN-Surveys, die siebenmal täglich per Cozie-App auf der Apple Watch präsentiert wurden © TU Wien

3.2.2.5 Ablauf

Die Studie wurde im Frühling 2025 durchgeführt. Der Ablauf umfasste vier Schritte:

- Screening-Umfrage zur Prüfung von Ein- und Ausschlusskriterien
- Informationsveranstaltung mit Einwilligung, Ausgabe/Einrichtung von Wearables und Sensorik sowie Einweisung
- vierwöchige Erhebungsphase mit sieben EMA-Prompts täglich und kontinuierlicher Sensor-/Wearable-Messung
- Ausfüllen des Onboarding-Umfrage unmittelbar nach Studienstart.

3.2.3 Datenaufbereitung

Nach Abschluss der Hauptstudie lagen die Rohdaten aus den in Kapitel 3.2.2 beschriebenen Quellen vor: Umgebungsdaten der stationären AirControl-Sensoren (Lufttemperatur, relative Luftfeuchte, CO₂-Konzentration), physiologische Daten der Apple Watch in Kombination mit der Cozie-App (Herzfrequenz, Aktivitätsindikatoren) sowie des Oura-Rings (Herzfrequenz, Herzratenvariabilität), die subjektiven Right-Here-Right-Now-Befragungen (RHRN) aus der Cozie-App und die einmalige Onboarding-Befragung mit demografischen, gebäudebezogenen und psychologischen Items.

Diese heterogenen Datenströme wurden in einem mehrstufigen Prozess in zwei konsolidierte Datensätze überführt: einen Hauptdatensatz, in dem jede Zeile einer einzelnen RHRN-Befragung mit

den zugehörigen Sensor- und Personenmerkmalen entspricht, sowie einen Cold-Start-Datensatz, der pro Teilnehmer:in die aggregierten demografischen und psychologischen Merkmale für die spätere Kohortenbildung enthält.

Vor der Zusammenführung wurde jede Datenquelle einzeln bereinigt und qualitätsgesichert. Bei den AirControl-Daten wurden offensichtlich fehlerhafte Zeitstempel korrigiert sowie Teilnehmer:innen identifiziert, für die keine oder nur unvollständige Sensordaten vorlagen.

Für die Herzfrequenz wurden die Messwerte von Apple Watch und Oura-Ring zusammengeführt. Die zur jeweiligen Befragung passenden Werte wurden in einem definierten Zeitfenster um den Survey-Zeitpunkt extrahiert; lagen aus beiden Geräten gleichzeitig Messwerte vor, wurde die Apple-Watch-Messung priorisiert. Zur Identifikation physiologisch unplausibler Werte und kurzzeitiger Mess-Artefakte kam ergänzend ein auf der Änderungsrate (Rate of Change) basierendes Detektionsverfahren zum Einsatz. Dieses prüft anhand eines Persistenz-Checks, ob eine auffällige Herzfrequenz-Änderung auf ein tatsächliches physiologisches Ereignis oder auf ein Sensor-Artefakt zurückzuführen ist.

Die Onboarding-Befragung wurde entsprechend den verwendeten psychologischen Skalen ausgewertet und zu den jeweiligen Score-Werten aggregiert. Dies umfasst die Berechnung der Heat- und Cold-Tolerance-Scores, der Lebenszufriedenheits-Skala (SWLS), der acht Subskalen des Multidimensional Assessment of Interoceptive Awareness (MAIA), der Persönlichkeitsdimensionen nach BFI-2-S und BFI-2-XS sowie der Symptom-Skalen des Brief Symptom Inventory (BSI).

Anschließend wurden die bereinigten Datenquellen über den Zeitpunkt der RHRN-Befragungen zusammengeführt: Jeder Befragung wurde das in einem definierten Vorfenster gemessene Sensor-Tupel aus Umgebungs- und Herzfrequenz-Daten zugeordnet. Inhaltlich wurden Befragungen ausgeschlossen, die keine validen Aussagen über thermisches Empfinden im Innenraum erlauben. Konkret betrifft dies Befragungen im Freien („Unterwegs“) und während intensiver körperlicher Aktivität („Sport“).

3.2.4 Komfortmodelle

Für die Modellierung des thermischen Komforts wurde der Ansatz der Cohort Comfort Models (CCM) nach Quintana et al. (2023) herangezogen. CCMs positionieren sich methodisch zwischen generalisierten Modellen wie dem Predicted Mean Vote (PMV), die keine individuellen Unterschiede berücksichtigen, und vollständig personalisierten Personal Comfort Models (PCM), die für jede Person ein eigenes Modell auf Basis individueller Daten trainieren. Der zentrale Gedanke des CCM-Ansatzes besteht darin, Personen mit ähnlichem Komfortempfinden datengetrieben zu Kohorten zusammenzufassen und pro Kohorte ein gemeinsames Vorhersagemodell zu erstellen. Dies ermöglicht eine personalisierte Komfortvorhersage auch für neue Personen, für die noch keine oder nur wenige individuelle Daten vorliegen.

Die Implementierung folgt der Referenz-Codebasis von Quintana et al. Das Repository wurde im Rahmen von PersonAI an den eigenen Datensatz und an spezifische Erweiterungen angepasst.

Die Modellierung erfolgt in vier Schritten:

- **Training der Personal Comfort Models:** Für jede Teilnehmer:in der Hauptstudie wird ein individuelles Random-Forest-Klassifikationsmodell trainiert, das auf Basis der erhobenen Sensor- und Personenmerkmale die thermische Präferenz vorhersagt. Die Hyperparameter-Optimierung erfolgt mittels Grid-Search und fünffacher Cross Validation; als Bewertungsmetrik dient der F1-micro-Score. Um das Ungleichgewicht der Input-Daten zu verringern, wurden in diesem Schritt Korrekturmaßnahmen implementiert, darunter ein Downsampling auf eine einheitliche Anzahl von Antworten pro Person, eine inverse Klassengewichtung im Modelltraining sowie ein synthetisches Oversampling mittels SMOTE-NC.
- **Ähnlichkeitsanalyse:** Auf Grundlage der trainierten PCMs werden zwei Ähnlichkeitsmaße berechnet: die Cross-Model-Performance, bei der das PCM jeder Person auf die Daten jeder anderen Person angewendet wird (ein hoher F1-Score deutet auf ähnliches Komfortverhalten hin), sowie die Verteilungsähnlichkeit der Komfortantworten, quantifiziert über die Jensen-Shannon-Divergenz der individuellen Antwortverteilungen (Cooler / No Change / Warmer). Beide Maße werden zu einer kombinierten Ähnlichkeitsmatrix zusammengeführt.
- **Kohortenbildung (Warm Start):** Auf der kombinierten Ähnlichkeitsmatrix wird ein Clustering durchgeführt; die optimale Kohortenanzahl wird anhand des Silhouette-Index bestimmt. Pro Kohorte wird anschließend ein eigenes Klassifikationsmodell auf den Daten aller Kohorten-Mitglieder trainiert. Dieser Pfad wird als Warm Start bezeichnet, da er sowohl Sensor- als auch Befragungsdaten der Teilnehmer:innen voraussetzt.
- **Kohortenbildung (Cold Start):** Parallel wird ein zweiter Pfad verfolgt, der die Kohorten ausschließlich auf Basis der einmalig erhobenen Onboarding-Daten bildet (Persönlichkeitsmerkmale, Komforttoleranz, demografische Angaben). Der Vorteil dieses Pfads liegt darin, dass neue Personen ausschließlich anhand ihrer Onboarding-Antworten einer Kohorte zugewiesen werden können, ohne dass dafür Sensor- oder Befragungsdaten erforderlich sind.

Auf Grundlage dieser Pipeline wurde Experimente mit unterschiedlichen Kombinationen aus Ähnlichkeitsgewichtung, Cluster-Verfahren, Feature-Auswahl und Resampling-Strategie durchgeführt. Daraus wurden je eine Cold-Start- und eine Warm-Start-Konfiguration für den Einsatz im Proof of Concept ausgewählt.

Aus den erzeugten Kohorten wird im nächsten Schritt der für den Gebäudebetrieb relevante Komfortbereich für die Raumtemperatur abgeleitet. Während die Modellierung der Gruppierung der Personen dient, werden die Komfortbereiche rein deskriptiv aus den Sensordaten der jeweiligen Kohorten-Mitglieder ermittelt.

Für jede Kohorte werden sämtliche Befragungen ihrer Mitglieder herangezogen, in denen die thermische Präferenz mit „Keine Veränderung“ angegeben wurde. Aus der Verteilung der zugehörigen

AirControl-Innentemperaturen ergeben sich pro Kohorte ein Temperatur-Sollwert, definiert als Mittelwert der Verteilung, sowie ein Komfortband, definiert durch den Interquartilsbereich (25. bis 75. Perzentil).

Für den Proof of Concept wurden mehrere Personen ausgewählt, deren Arbeitsplätze in den Gebäuden des Projektpartners Forschung Burgenland für eine kohortenbasierte Temperaturregelung geeignet waren. Die Zuordnung dieser Personen zu einer Kohorte erfolgte über beide Modellierungspfade: im Cold-Start-Pfad auf Basis eines eigens durchgeführten verkürzten Onboarding-Fragebogens, der die für die jeweilige Konfiguration relevanten Merkmale erhebt; im Warm-Start-Pfad auf Basis der Vorhersage-Performance der trainierten Kohorten-Modelle auf einer kleinen Anzahl gelabelter Datenpunkte der jeweiligen Person.

Die Durchführung des PoC erfolgte in zwei aufeinanderfolgenden Phasen: In einer Referenzwoche wurde der reguläre Gebäude-Setpoint beibehalten. In der darauffolgenden Cohort-Woche wurden die kohortenspezifischen Komfort-Sollwerte als Temperatur-Setpoints an den Arbeitsplätzen der zugeordneten Personen eingestellt. Als Erfolgsmetrik diente die Komfort-Zufriedenheit, operationalisiert als prozentualer Anteil der RHRN-Antworten mit der Präferenz „Keine Veränderung“ im jeweiligen Erhebungszeitraum.

Zur Überprüfung der Plausibilität der Kohortenzuordnung wurde im Cold-Start-Pfad ergänzend ein Validierungs-Setup umgesetzt. Ein Teil der PoC-Teilnehmer:innen wurde bewusst einer abweichenden Kohorte zugeordnet.

Neben der Auswirkung auf die subjektive Komfort-Zufriedenheit wurde im Rahmen des Proof of Concept auch untersucht, welchen Einfluss die kohortenbasierte Setpoint-Steuerung auf den Energieverbrauch und die Energieflexibilität des Gebäudes hat.

3.2.5 Auswirkung des Komfortbandes auf den Energieverbrauch

Im vorliegenden Forschungsvorhaben wurde ein bestehendes datengetriebenes Framework zur modellprädiktiven Regelung thermischer Gebäudezonen auf eine definierte Reihe von Simulationsszenarien angewendet. Die methodische Grundlage bildet ein integriertes Entwicklungs- und Simulationsframework zur Abbildung der thermischen Dynamik von Gebäudezonen auf Basis datengetriebener Grey-Box-Zustandsraummodelle, wie in Klanatsky et al. (2025c) beschrieben. Das Framework ermöglicht die konsistente Modellierung, Simulation und Bewertung unterschiedlicher Regelungsstrategien für thermische Zonen und ist insbesondere auf Gebäude mit thermisch aktivierten Bauteilsystemen (TABS), hohen solaren Lasten und regelbaren Verschattungssystemen ausgerichtet. Die Validierung erfolgte anhand von Messdaten eines Living-Lab-Bürogebäudes über mehr als ein Jahr; berichtet werden mittlere absolute Fehler von unter 0,5 °C für alle betrachteten Zonen bei Simulationszeitschritten von 1 min und 15 min (Klanatsky et al., 2025c).

Eine zentrale Grundlage des Frameworks ist die zustandsraumbasierte Beschreibung der thermischen Zonendynamik mithilfe datengetriebener Grey-Box-Modelle. Darauf aufbauend wird ein datengetriebener modellprädiktiver Regelungsansatz (DMPC) formuliert, der besonders für Gebäude mit hoher thermischer Speichermasse, TABS und signifikanten solaren Einträgen geeignet ist. Die anwendungsbezogene Einbettung für Gebäude mit Glasfassade und thermisch aktivierter Gebäudestruktur ist in Klanatsky et al. (2025b) beschrieben. Eine belastbare und effiziente MILP-Formulierung des zugrunde liegenden Optimierungsproblems, insbesondere für die kombinierte Regelung von TABS und Verschattung, ist in Klanatsky et al. (2025a) dokumentiert. Charakteristisch ist, dass thermische Komfortanforderungen als Nebenbedingungen formuliert werden, ohne Gewichtungsfaktoren in der Zielfunktion zu verwenden. Dadurch wird eine methodisch nachvollziehbare und reproduzierbare Optimierungsgrundlage für datengetriebene prädiktive Regelungsverfahren im Gebäudebereich bereitgestellt (Klanatsky et al., 2025a; 2025b; 2025c).

Für das gegenständliche Projekt ist wesentlich, dass die in den Projekten „scaleFLEX“ und „Hub4FIECs“ vorgenommenen Erweiterungen nicht Gegenstand des hier beschriebenen Forschungsvorhabens waren. Dies betrifft insbesondere die in „scaleFLEX“ (FFG, 2026a) umgesetzte zentrale Simulation von N thermischen Zonen mittels DMPC sowie eine weitere Umgebung zur sequentiellen zonenweisen Simulation von N thermischen Zonen mittels DMPC. In „Hub4FIECs“ (FFG, 2026b) wurde das Framework zudem um die Berücksichtigung unterschiedlicher elektrischer Energiequellen ergänzt, insbesondere aus PV-System, Energiegemeinschaft und Energieversorger.

Das vorliegende Projekt verfolgte demgegenüber nicht das Ziel, das bestehende Framework um zentrale Mehrzonenoptimierung, verteilte sequentielle Zonensimulation oder energiewirtschaftliche Quellmodelle zu erweitern. Im Mittelpunkt stand vielmehr die methodisch konsistente Anwendung des bereits publizierten Simulations-, Modellierungs- und Optimierungsinstrumentariums auf eine klar definierte Anzahl vergleichbarer Untersuchungsszenarien. Ziel war die systematische Analyse des Einflusses unterschiedlicher Komfortbänder und Regelungsstrategien auf den Energieverbrauch unter einheitlichen Randbedingungen. Das Projekt knüpft damit unmittelbar an die in den genannten Publikationen dokumentierten methodischen Grundlagen an, ohne die funktionalen Erweiterungen aus „scaleFLEX“ und „Hub4FIECs“ selbst zum Gegenstand der Arbeiten zu machen.

Im Rahmen des Projekts wurden insgesamt acht Simulationsszenarien definiert und ausgewertet. Die Untersuchungen beziehen sich auf die beiden Gebäude ENERGETIKUM und LOWERGETIKUM, für die jeweils zwei thermische Komfortbänder betrachtet wurden. Komfortband A umfasst einen zulässigen Temperaturkorridor von 21,5 °C bis 23,4 °C, Komfortband B einen Bereich von 21,8 °C bis 24,5 °C. Für jedes Komfortband wurden zwei Regelungsstrategien untersucht: ein konventioneller Zweipunktregler sowie ein DMPC-Algorithmus mit stündlicher Re-Optimierung. Daraus ergibt sich je Gebäude eine identische Versuchsstruktur mit vier Einzelsimulationen und insgesamt acht methodisch äquivalenten Simulationsfällen.

Die Auswertung erfolgt nicht nur aggregiert über den Gesamtjahresverlauf, sondern getrennt nach Heiz- und Kühlsaison. Diese Differenzierung ist methodisch erforderlich, da sich thermodynamische

Randbedingungen, dominante Lastanteile, Wirkmechanismen der TABS und regelungstechnische Anforderungen in beiden Betriebsregimen wesentlich unterscheiden. Während in der Heizsaison insbesondere die Einhaltung der unteren Komfortgrenze, die träge Wärmebereitstellung und die Vermeidung von Untertemperaturen im Vordergrund stehen, dominieren in der Kühltisaison solare Einträge, die Begrenzung von Übertemperaturen sowie die Wechselwirkung zwischen Kühltisbetrieb und Verschattung. Die saisonal getrennte Bewertung ermöglicht daher eine differenzierte und wissenschaftlich belastbare Beurteilung der untersuchten Regelungsansätze.

3.2.5.1 Beschreibung der Versuchsgebäude

3.2.5.1.1 ENERGETIKUM

Das Living Lab ENERGETIKUM ist durch eine überwiegend verglaste Gebäudehülle gekennzeichnet und eignet sich insbesondere zur Untersuchung des Einflusses transparenter Fassadenflächen auf den thermischen Gebäudebetrieb, den sommerlichen Komfort und die Regelungsstrategien. Im Zusammenhang mit der großflächigen Verglasung kommt einer automatisierten bzw. regelungsbasierten Jalousiesteuerung besondere Bedeutung zu; ergänzend wird auf das Paper „Energy demand reduction due to an intelligent shading control strategy“ verwiesen (Klanatsky et al., 2020). Das ENERGETIKUM zeichnet sich damit durch die Kombination aus großen Glasflächen, thermisch aktivierten Bauteilsystemen (TABS) und regelbarer Verschattung aus, wodurch neben der thermischen Speichermasse auch die äußeren Lasten aktiv beeinflusst werden können. In Abbildung 6 ist die Außenansicht des ENERGETIKUMs zu sehen.



Abbildung 6: Living Lab ENERGETIKUM © Forschung Burgenland

Die technische Infrastruktur des Living Lab ENERGETIKUM umfasst eine moderne Gebäudeautomation, leistungsfähige Kommunikationsnetzwerke und ein umfangreiches Messsystem mit rund 12.000 physischen und virtuellen Datenpunkten. Durch die kontinuierliche Datenerfassung in einem Cloud-System ist ein umfassendes Langzeitmonitoring möglich. Erfasst werden unter anderem Wetterdaten sowie gebäude- und raumbezogene Messgrößen wie Temperatur, relative Feuchte und CO₂-Konzentration. Über eine API-Schnittstelle ist es möglich, auch extern auf aktuelle und historische Daten zuzugreifen. Darüber hinaus stehen für das Living Lab ENERGETIKUM historische Datenreihen seit 2018 zur Verfügung, die eine fundierte Grundlage für weiterführende Analysen sowie Anwendungen im Bereich maschinelles Lernen und Deep Learning bilden.

Die Wärme- und Kältebereitstellung erfolgt über eine reversible Wärmepumpe. Hervorzuheben ist dabei die Art der Wärme- und Kälteabgabe: Die Lüftungsanlage dient im Wesentlichen dem hygienisch erforderlichen Luftwechsel sowie der isothermen Lufteinbringung, während die Raumheizung über die Fußbodenheizung und die Raumkühlung über die Betonkernaktivierung in den Decken erfolgt.

In den Simulationsräumen sind die einzelnen Abgabesysteme individuell regelbar; zusätzlich können Zu- und Abluftvolumenströme eingestellt werden. Dadurch eignet sich das Gebäude besonders zur Untersuchung des Zusammenspiels aus internen Lasten, solaren Einträgen, Fassadenverschattung, thermischer Speichermasse und anlagentechnischer Regelung. Jeder Raum ist mit Sensorik zur Erfassung von Temperatur, Feuchte und CO₂ ausgestattet, wodurch eine detaillierte Bewertung von Komfort- und Betriebszuständen möglich ist.

3.2.5.1.2 LOWERGETIKUM

Das Living Lab LOWERGETIKUM verfolgt ein bauphysikalisch deutlich reduzierteres und auf thermische Stabilität ausgerichtetes Gebäudekonzept verglichen mit dem ENERGETIKUM. Es wurde in schwerer Bauweise mit möglichst geringem Glasanteil bzw. normal dimensionierten Fenstern errichtet und bildet damit einen bewussten Kontrast zum Living Lab ENERGETIKUM. Durch diese Konzeption können Fragestellungen zu energieeffizientem Gebäudebetrieb, reduzierten solaren Lasten und dem Verhalten thermisch träger Gebäudestrukturen unter realen Nutzungsbedingungen untersucht werden. Das LOWERGETIKUM weist ebenfalls thermisch aktivierte Bauteilsysteme (TABS) auf; im Unterschied zum Energetikum steht jedoch keine regelbare Verschattung zur Verfügung.

Die Wärme- und Kältebereitstellung erfolgt über eine reversible Wärmepumpe. Sowohl die Wärme als auch die Kälteabgabe werden über ein Change-Over-System mit Betonkernaktivierung realisiert. Damit steht die Nutzung der Gebäudemasse als thermischer Speicher im Zentrum des Konditionierungskonzepts. Der Luftwechsel erfolgt über eine Komfortlüftung mit regenerativer Wärmerückgewinnung. Die Betonkernaktivierung ist pro Geschoss jeweils getrennt für Nord- und Südzone regelbar; die Zuluft wird über Überströmöffnungen geführt. In Abbildung 7 ist die Außenansicht des LOWERGETIKUMs zu sehen.



Abbildung 7: Living Lab LOWERGETIKUM © Forschung Burgenland

Auch im LOWERGETIKUM ist jeder Raum mit Sensorik für Temperatur, Feuchte und CO₂ ausgestattet. Dadurch können sowohl das thermische Verhalten des Gebäudes als auch die Wirksamkeit zentraler Regelungsstrategien detailliert analysiert und mit dem Betrieb des ENERGETIKUMS verglichen werden.

3.2.5.2 Festlegung der Regelstrategien

3.2.5.2.1 Zweipunktregler inkl. Verschattungsregelung

Abbildung 8 veranschaulicht das Schaltprinzip der im Projekt verwendeten Zweipunktregler einschließlich der temperaturabhängigen Verschattungsregelung. Dargestellt ist die Schalthysterese der beiden thermischen Teilsysteme in Abhängigkeit von der Raumtemperatur T_{Room} , unterschieden nach Heizsystem (rot) und Kühlsystem (blau). Der Zweipunktregler basiert nicht auf einem kontinuierlich optimierten Komfortband, sondern auf fest vorgegebenen temperaturabhängigen Ein- und Ausschaltschwellen. Beim Heizsystem wird bei Unterschreitung des Heiz-Sollwertes der ON-Zustand ausgelöst; abgeschaltet wird erst nach Überschreitung der oberen Hystereseschwelle. Beim Kühlsystem erfolgt die Aktivierung entsprechend bei Überschreitung des Kühl-Sollwertes, die Deaktivierung nach Unterschreitung der unteren Hystereseschwelle. Die Größen $\Delta T_{SET,heating}$ bzw. $\Delta T_{SET,cooling}$ bezeichnen die Breite der Schalthysterese zwischen Ein- und Ausschaltschwelle.

Die beiden untersuchten Komfortbänder wurden in äquivalente Parameter des Zweipunktreglers überführt. Für den 2P-Regler A, entsprechend Komfortband A, wurden ein Heiz-Sollwert von 22,0 °C und ein Kühl-Sollwert von 22,9 °C festgelegt; für beide Teilsysteme wurde dieselbe Hysterese angesetzt. Für den 2P-Regler B, entsprechend Komfortband B, ergeben sich ein Heiz-Sollwert von 22,3 °C und ein Kühl-Sollwert von 24,0 °C, ebenfalls bei identischer Hysterese.

Zusätzlich zeigt Abbildung 8 die temperaturabhängige Verschattungsregelung. Die Verschattungshöhe wird – sofern baulich möglich – im Temperaturbereich zwischen Heiz- und Kühl-Sollwert von 0 auf 1 geführt, wobei der Kippwinkel konstant auf 90° gesetzt wird. Für den 2P-Regler A erfolgt diese Ansteuerung somit im Bereich von 22,0 °C bis 22,9 °C, für den 2P-Regler B im Bereich von 22,3 °C bis 24,0 °C. Damit wird für beide Reglerkonfigurationen eine konsistente Abbildung der zugrunde gelegten Komfortbänder auf einen konventionellen, nicht-prädiktiven Regelungsansatz sichergestellt.

Der Zweipunktregler erfüllt die thermischen Anforderungen somit nicht durch Optimierung eines zukünftigen Systemverhaltens, sondern ausschließlich reaktiv über definierte Schaltschwellen und Hysteresen. Die in Abbildung 8 dargestellten Parametrierungen bilden daher die Vergleichsbasis für die Gegenüberstellung mit den untersuchten DMPC-Regelungsstrategien.




Abbildung 8: Parameter des Zweipunktreglers © Forschung Burgenland

3.2.5.2.2 DMPC-Algorithmus zur TABS-Regelung und Regelung der Verschattung

Abbildung 9 zeigt die dem datengetriebenen modellprädiktiven Regler (DMPC) zugrunde gelegten thermischen Komfortgrenzen. Im Unterschied zum Zweipunktregler erfolgt keine Überführung des Komfortbandes in separate Heiz- und Kühl-Sollwerte mit zugehörigen Hysteresen. Stattdessen werden die unteren und oberen Temperaturgrenzen direkt als zulässige Randbedingungen für die Raumtemperatur T_{Room} in das Optimierungsproblem eingebracht. Das Komfortband definiert damit unmittelbar den zulässigen Zustandsraum, innerhalb dessen sich die vorhergesagte und geregelte Raumtemperatur bewegen darf.

Für Komfortband A wird ein zulässiger Temperaturbereich von 21,5 °C bis 23,4 °C vorgegeben, für Komfortband B ein Bereich von 21,8 °C bis 24,5 °C. Diese Grenzwerte bilden die thermischen Nebenbedingungen der prädiktiven Regelung und beschreiben die im Rahmen der Optimierung einzuhaltenden Komfortanforderungen.

Im Unterschied zur reaktiven Logik des Zweipunktreglers mit festen Schaltschwellen und Hysterese berücksichtigt der DMPC die Komfortgrenzen im Rahmen einer vorausschauenden Regelungsstrategie. Die Regelentscheidung erfolgt daher nicht ausschließlich auf Basis der aktuell gemessenen Raumtemperatur, sondern durch prädiktive Optimierung unter Berücksichtigung des zukünftigen Systemverhaltens. Die in Abbildung 9 dargestellten Komfortbänder bilden somit die unmittelbare methodische Grundlage für die Formulierung der Komfortanforderungen im DMPC.




Abbildung 9: thermische Nebenbedingungen der prädiktiven Regelung © Forschung Burgenland

Durch diese Festlegung wird eine konsistente Vergleichsbasis für die Untersuchung der DMPC-Variante geschaffen. Gemeinsam mit der für den Zweipunktregler vorgenommenen Parametrierung lassen sich damit beide Regelungsstrategien unter vergleichbaren thermischen Komfortanforderungen analysieren und hinsichtlich ihres Einflusses auf den Energieverbrauch gegenüberstellen.

3.2.6 Replikationsstudie

Über die Durchführung und energetische Bewertung des Proof of Concept hinaus wurde die dem Projekt zugrunde liegende Modellierungs-Pipeline einer systematischen methodischen Überprüfung unterzogen. Anlass dafür waren zum einen die im PoC beobachteten Befunde, die keinen eindeutigen Komfort-Effekt der Kohortenzuordnung zeigten, zum anderen eine vertiefte Analyse der Referenz-Codebasis im Zuge der wissenschaftlichen Aufarbeitung. Im Rahmen dieser Analyse wurden mehrere methodische Schwachstellen in der Codebasis und im Versuchsdesign der Originalpublikation (Quintana et al., 2023) identifiziert. Um diese Punkte systematisch zu adressieren, wurde eine Reproduktionsstudie durchgeführt, die sowohl die Originaldaten (DORN-Datensatz) als auch den PersonAI-Datensatz umfasst.

Methodik und Experimente folgen dabei grundsätzlich der Originalpublikation. Die Codebasis wurde jedoch in den folgenden Punkten überarbeitet:

- **Evaluierungsstrategie:** Anstelle der im Original verwendeten 100 randomisierten 80/20-Train/Test-Splits wird eine personenbezogene Leave-One-Out-Cross-Validation (LOOCV) eingesetzt. Wiederholtes zufälliges Splitten erzeugt bei Datensätzen mit weniger als 50 Teilnehmer:innen eine hohe Ergebnisvarianz und bietet keine Garantie, dass alle Personen als Testfall berücksichtigt werden. LOOCV gilt für kleine Datensätze als verzerrungsärmster Estimator der Generalisierungsleistung (Yates et al., 2023; Cawley & Talbot, 2010) und ist in diesem Fall zudem rechnerisch weniger aufwändig.

- **Hyperparameter-Optimierung:** Die im Original eingesetzte Hyperparameter-Optimierung wurde vollständig entfernt. Stattdessen werden die Standardparameter des scikit-learn Random Forest verwendet. Das ursprüngliche Verfahren führte dazu, dass jedes der 100 Experimente auf Modellen mit unterschiedlichen Parametern basierte, erheblichen Rechenaufwand verursachte und nur vernachlässigbare Leistungsverbesserungen brachte. Hinzu kommt, dass in der Originalpublikation (Quintana et al., 2023) die Hyperparameter auf denselben Daten optimiert wurden, auf denen anschließend die Leistung evaluiert wurde, was eine zusätzliche Form von Information Leak darstellt.
- **Behebung identifizierter Information Leaks:** In der Referenz-Codebasis werden die Modell-Features durch Ausschluss unerwünschter Spalten bestimmt, anstatt die gewünschten Features explizit auszuwählen. Durch das Standardverhalten von pandas, den Dataframe-Index beim Speichern als CSV mitzuschreiben und beim erneuten Laden als eigene Spalte einzulesen, wurde diese Index-Spalte versehentlich als Feature verwendet. Da die zugrunde liegenden Datensätze mehrere Jahreszeiten umfassen, gelangten auf diesem Weg temporale Informationen ins Modell, die zu überhöhten Leistungswerten führten. Der Fehler wurde durch den expliziten Ausschluss der betreffenden Spalte behoben. Aufgrund fehlender versionierter Code- und Datensatz-Releases der Originalautoren lässt sich der genaue Zustand der ursprünglichen Experimente jedoch nicht rekonstruieren.
- **Bewertungsmetrik:** Die Reproduktionsstudie ergänzt die im Original verwendete F1-Micro-Metrik um F1-Macro-Werte. F1-Micro leidet bei stark unbalancierten Daten unter denselben Schwächen wie die Accuracy: Die Metrik spiegelt wider, wie gut ein Modell die Mehrheitsklasse trifft, nicht jedoch seine tatsächliche Klassifikationsfähigkeit über alle Klassen hinweg. Zusätzlich wird die Vorhersage der Mehrheitsklasse als explizite Baseline eingeführt, um die Leistungsfähigkeit der Modelle besser einordnen zu können.

3.3 Bewertung der angewendeten Methoden

Das gewählte Erhebungsdesign, mit der Kombination aus Wearables (Apple Watch, Oura Ring), stationären Umgebungssensoren (AirCO2ntrol) und wiederholten RHRN-Kurzbefragungen über die Cozie-App, hat sich in der Umsetzung grundsätzlich bewährt. Die technische Infrastruktur funktionierte über den Studienzeitraum stabil, und die Teilnehmer:innen konnten die Geräte im Alltag ohne größere Einschränkungen verwenden. Die Datenaufbereitung, insbesondere die zeitliche Zuordnung der Sensorwerte zu den Befragungen und die Aggregation der Herzfrequenz aus zwei Wearables, ließ sich zuverlässig durchführen.

Eine methodische Herausforderung stellte die Verteilung der Komfortantworten dar. Die Klasse „Keine Veränderung“ dominierte bei nahezu allen Teilnehmer:innen, wodurch die für die Modellierung relevanten Klassen „Kühler“ und „Wärmer“ nur schwach besetzt waren. Da der Erhebungszeitraum mit vier Wochen im Frühling keine ausgeprägten Hitze- oder Kälteperioden umfasste, konnte

die Studie nur einen begrenzten Ausschnitt möglicher thermischer Bedingungen abbilden. Für zukünftige Studien wäre ein längerer Erhebungszeitraum über mehrere Jahreszeiten empfehlenswert, um eine breitere Varianz in den Komfortantworten zu erzielen.

Die Übernahme der CCM-Methodik nach Quintana et al. (2023) und deren Referenz-Codebasis war eine bewusste methodische Entscheidung, um auf einer bereits publizierten Grundlage aufzubauen. Die Pipeline ließ sich auf den PersonAI-Datensatz anpassen und eine Experimentreihe konnte durchgeführt werden. Im weiteren Projektverlauf warf dieser Ansatz aber methodische Fragen auf, die weiter unten beschrieben werden.

Das zweiphasige PoC-Design (Referenzwoche / Cohort-Woche) erwies sich als praktikabler Ansatz, um kohortenbasierte Komfort-Sollwerte unter realen Gebäudebedingungen zu erproben. Die technische Umsetzung in der Gebäudeautomation des Energetikum-Gebäudes war machbar, und die Zuordnung der PoC-Teilnehmer:innen über die beiden Modellierungspfade konnte wie geplant durchgeführt werden. Auch das ergänzende Validierungs-Setup mit bewusst falscher Kohortenzuordnung ließ sich umsetzen und erwies sich als methodisch wertvoller Bestandteil des Versuchsdesigns, da es eine Unterscheidung zwischen Kohorten-Effekt und unspezifischen Einflussfaktoren ermöglicht. Einschränkend ist anzumerken, dass die Stichprobengröße im PoC die statistische Aussagekraft der Ergebnisse begrenzt.

Nach Abschluss des PoC und im Zuge der wissenschaftlichen Aufarbeitung fielen in der Codebasis Einschränkungen auf, die methodische Korrekturen erforderten, darunter die Handhabung der Feature-Selektion und die Eignung der verwendeten Bewertungsmetrik bei stark unbalancierten Daten. Diese Beobachtungen führten zur Erarbeitung der in Kapitel 3.2.6 beschriebenen Reproduktionsstudie, deren Ergebnisse in Kapitel 4.4 dokumentiert sind.

4 Ergebnisse

4.1 Datenaufbereitung

Von den ursprünglich 83 in die Hauptstudie aufgenommenen Personen verbleiben im finalen Datensatz, nach Bereinigung und Anwendung der oben beschriebenen Ausschlusskriterien, 72 Personen mit verwertbaren Sensordaten, darunter 40 Frauen (Alter: $M = 32,3$, $SD = 9,0$, Spannweite = 18–64). Die Stichprobe war hoch gebildet (9 Doktorat, 28 Master-, 20 Bachelorabschlüsse; 15 Matura). Auf Basis von BMI und Selbstauskunft waren die Teilnehmenden gesund (BMI: $M = 23,4$, $SD = 3,4$); 92 % berichteten regelmäßige körperliche Aktivität. Die Wohnsituation verteilte sich auf Wohnungen (75 %), Einfamilien- (19 %) und Reihenhäuser (6 %).

Insgesamt umfasst der Hauptdatensatz rund 7.600 Befragungs-Zeilen mit je einem zugehörigen Sensor-Tupel aus Umgebungs- und physiologischen Messwerten. Der Cold-Start-Datensatz enthält die zugehörigen psychologischen und demografischen Merkmale auf Personenebene.

Bereits in der explorativen Analyse zeigte sich, dass sowohl die Anzahl der Befragungen pro Person als auch die Verteilung der drei Komfortklassen („Kühler“, „Wärmer“, „Keine Veränderung“) deutlich ungleich verteilt sind. Dieses Ungleichgewicht zeigt sich in zwei Dimensionen.

Erstens weichen die Teilnehmer:innen stark in der Anzahl der von ihnen abgegebenen Befragungen voneinander ab. Während der Durchschnitt bei rund 116 Befragungen pro Person liegt, schwankt die tatsächliche Antwortzahl zwischen rund 50 und nahezu 300. Personen mit besonders hoher Beteiligung würden ein gemeinsam trainiertes Modell unverhältnismäßig prägen, wenn dieses Ungleichgewicht nicht aktiv adressiert wird.

Zweitens ist die Verteilung der Zielvariable (thermische Präferenz) sowohl auf Gesamt- als auch auf Personenebene stark unausgeglichen. Die Antwortkategorie „Keine Veränderung“ dominiert bei nahezu allen Teilnehmer:innen, oft mit Anteilen zwischen 60% und über 95%. Die Klassen „Kühler“ und „Wärmer“ sind in vielen Fällen entsprechend selten besetzt (siehe Abbildung 10).




Abbildung 10: Thermische Präferenz der Teilnehmer:innen © TU Wien

Die Auswertung der aufbereiteten Daten lässt zusätzlich erkennen, dass die drei Komfortklassen anhand der erhobenen Merkmale nur eingeschränkt trennbar sind. Die Verteilungen der zentralen Sensor-Merkmale (Lufttemperatur, Luftfeuchte, CO₂, Herzfrequenz) überlappen über alle drei Klassen hinweg deutlich (siehe Abbildung 11).




Abbildung 11: Verteilung der Sensor-Merkmale über die Komfortklassen © TU Wien

Eine Principal Component Analysis (PCA) über die kombinierten numerischen und kategorialen Merkmale zeigt zudem, dass sich die Datenpunkte pro Person gruppieren, nicht jedoch nach Komfortklasse. Die Daten unterscheiden sich also stärker danach, von wem sie stammen, als danach, welche Komfortklasse sie repräsentieren.

4.2 Komfortmodelle

Die Cold-Start-Kohortenbildung ergab zwei Cluster mit nahezu identischen Komfortpräferenzen gem. Tabelle 1:

Tabelle 1: Mittlere Komforttemperaturen der Cold-Start-Kohorten

Kohorte	Mittlere Komforttemperatur
C0	23,1 °C
C1	23,0 °C

Bei einer Differenz von 0,1 °C ist eine Unterscheidung in getrennte Setpoint-Bereiche nicht sinnvoll begründbar. Die beiden Cold-Start-Cluster wurden daher zu einer einzigen Kohorte konsolidiert.

Im Warm-Start-Pfad ließen sich gem. Tabelle 2 drei thermisch unterscheidbare Kohorten identifizieren:

Tabelle 2: Mittlere Komforttemperaturen der Warm-Start-Kohorten

Kohorte	Mittlere Komforttemperatur
W0	23,0 °C
W1	21,3 °C
W2	23,7 °C

Die mittlere Komforttemperatur der Kohorte W0 stimmt praktisch vollständig mit jener der konsolidierten Cold-Start-Kohorte überein. Die deutlichste Abweichung weist Kohorte W1 mit einer um knapp zwei Grad niedrigeren Komforttemperatur auf. Dieser Kohorte wurden im Rahmen des PoC jedoch keine Teilnehmer:innen zugeordnet, weshalb sie für die praktische Umsetzung nicht zum Tragen kam.

Aus diesen Ergebnissen ergaben sich für den Proof of Concept zwei finale Kohorten mit folgenden Sollwerten und Komfortbändern gem. Tabelle 3:

Tabelle 3: Finale Kohorten für das Proof of Concept mit Sollwerten und Komfortbändern

Kohorte	Mittlere Komforttemperatur	Komfortband (IQR)
C0 / W0	23,1 °C	21,5-23,4 °C
W2	23,0 °C	21,8-24,5 °C

Auf Basis dieser Komfortbereiche wurde das Proof of Concept durchgeführt, an dem insgesamt 16 Personen im Cold-Start-Pfad teilnahmen, von denen vier zur Validierung bewusst einer abweichenden Kohorte zugeordnet wurden. Fünf Personen wurden dem Warm-Start-Pfad zugeordnet (4 Personen in Kohorte W0, 1 Person in Kohorte W2).

Im Warm-Start-Pfad lag die Komfort-Zufriedenheit in der Referenzwoche bei 57,1 % (n = 70) und in der Cohort-Woche bei 57,9 % (n = 57). Die Differenz von unter einem Prozentpunkt liegt innerhalb

der erwartbaren Schwankungsbreite und stellt keine belastbare Veränderung dar. (siehe Abbildung 12)




Abbildung 12: Rückmeldungen Zufriedenheit - Warm Start © TU Wien

Im Cold-Start-Pfad stieg die Zufriedenheit von 64,3% in der Referenzwoche (n = 207) auf 75,6% in der Cohort-Woche bei korrekter Kohortenzuordnung (n = 123). Die bewusst einer abweichenden Kohorte zugeordneten Personen wiesen jedoch mit 76,2% (n = 21) einen vergleichbaren Zufriedenheitswert auf (siehe **Fehler! Verweisquelle konnte nicht gefunden werden.**). Da der Anstieg auch bei nicht-korrektur Kohortenzuordnung in ähnlicher Größenordnung zu beobachten ist, lässt sich die Verbesserung gegenüber der Referenzwoche nicht eindeutig auf die kohortenbasierte Setpoint-Steuerung zurückführen.




Abbildung 13: Rückmeldungen Zufriedenheit - Cold Start © TU Wien

Neben der Auswirkung auf die subjektive Komfort-Zufriedenheit wurde im Rahmen des Proof of Concept auch untersucht, welchen Einfluss die kohortenbasierte Setpoint-Steuerung auf den Energieverbrauch und die Energieflexibilität des Gebäudes hat.

4.3 Auswirkung des Komfortbandes auf den Energieverbrauch

4.3.1 Einhaltung des Komfortbandes ENERGETIKUM

Abbildung 14 und Abbildung 15 zeigen die zeitlichen Verläufe der simulierten Raumlufttemperaturen der betrachteten Zonen im ENERGETIKUM für die untersuchten Regelungsstrategien Zweipunktregler und DMPC mit stündlicher Re-Optimierung. Die obere Teilgrafik bezieht sich jeweils auf Komfortband A mit Temperaturgrenzen von 21,5 °C bis 23,4 °C, die untere auf Komfortband B mit 21,8 °C bis 24,5 °C. Die gestrichelten Linien markieren die zulässigen Komfortgrenzen. Rot hinterlegte Zeiträume kennzeichnen die Heizphase, blau hinterlegte die Kühlphase. In der Heizphase ist die Kühlung deaktiviert, in der Kühlphase die Heizung. Die Einhaltung des Komfortbandes ist daher stets im Kontext der jeweils verfügbaren Betriebsart zu bewerten: Überschreitungen der oberen Komfortgrenze können in der Heizphase nicht aktiv durch Kühlung kompensiert werden, Unterschreitungen der unteren Komfortgrenze in der Kühlphase nicht durch Heizen. Das Komfortband ist somit kein

ganzjährig uneingeschränkt aktiv regelbarer Temperaturkorridor, sondern ein saisonal begrenzter Zielbereich.

Vor diesem Hintergrund zeigt der Zweipunktregler (Abbildung 14) ein ausgeprägt schaltinduziertes, oszillierendes Verhalten. Die Raumtemperaturen pendeln reaktiv zwischen unteren und oberen Temperaturbereichen, wodurch insbesondere bei Übergängen und Laständerungen wiederholt Grenznäherungen und kurzzeitige Grenzverletzungen auftreten. In der Heizphase betrifft dies vor allem Situationen mit erhöhten solaren Einträgen, in denen die Temperatur an die obere Komfortgrenze heranreicht oder diese überschreitet, ohne dass eine aktive Gegenwirkung durch Kühlung möglich ist. In der Kühlphase treten entsprechend Unterschreitungen der unteren Komfortgrenze auf, die aufgrund der deaktivierten Heizung nicht aktiv kompensiert werden können.




Abbildung 14: Temperaturverläufe 2P-Regler (oben: Komfortband A; unten: Komfortband B) © Forschung Burgenland

Die DMPC-Variante zeigt demgegenüber eine deutlich strukturiertere und vorausschauendere Temperaturführung (Abbildung 15). Die Verläufe sind weniger von starren Schaltvorgängen geprägt und nutzen den innerhalb der jeweiligen Saison verfügbaren Komfortbereich gezielter aus. Dabei operiert die Regelung in der Heizphase tendenziell näher an der unteren Komfortgrenze und in der Kühlphase näher an der oberen Komfortgrenze. Dieses Verhalten ist unter dem Ziel der Energiebedarfsminimierung plausibel, da in der Heizphase ein Betrieb nahe der unteren Komfortgrenze und in der Kühlphase ein Betrieb nahe der oberen Komfortgrenze energetisch günstig ist.



Abbildung 15: Temperaturverläufe dezentraler DMPC mit stündlicher Re-Optimierung (oben: Komfortband A; unten: Komfortband B) © Forschung Burgenland

Gleichzeitig zeigen die Abbildungen, dass selbst bei prädiktiver Regelung Komfortabweichungen in die jeweils nicht aktiv beeinflussbare Richtung nicht vollständig vermeidbar sind. Die Einhaltung des Komfortbandes hängt daher nicht allein vom Regelalgorithmus ab, sondern auch von der Gebäudestruktur und den verfügbaren Stellgrößen. Im ENERGETIKUM bestehen mit großen Glasflächen, TABS und regelbarer Verschattung zwar zusätzliche Freiheitsgrade zur Beeinflussung innerer und äußerer Lasten, dennoch bleibt die Komforteinhaltung saisonal durch die jeweilige Betriebsart begrenzt.

Insgesamt zeigen die Ergebnisse für das ENERGETIKUM, dass die DMPC-Variante das Komfortband systematischer und ruhiger ausnutzt als der Zweipunktregler. Zugleich wird deutlich, dass die festgelegten Komfortbänder stets im Zusammenhang mit der saisonalen Verfügbarkeit von Heiz- bzw. Kühlleistung interpretiert werden müssen.

4.3.2 Jahresenergieverbrauch ENERGETIKUM

Die Unterschiede in der Regelungscharakteristik spiegeln sich unmittelbar in den ausgewiesenen Jahresenergiebedarfen wider. Für das engere Komfortband A (21,5 °C bis 23,4 °C) ergibt sich gegenüber dem Zweipunktregler für die DMPC-Variante eine deutliche Reduktion des Energiebedarfs (Tabelle 4). Der elektrische Energiebedarf der Wärmepumpe sinkt von 8924,3 kWh/a auf 5103,6 kWh/a und damit um 42,8 %. Der Heizenergiebedarf der TABS reduziert sich von 26031,1 kWh/a auf

14164,0 kWh/a, entsprechend 45,6 %. Der Kühlenergiebedarf liegt mit 1860,4 kWh/a geringfügig um 1,4 % über dem Wert des Zweipunktreglers.

Tabelle 4: Gesamter Energiebedarf pro Jahr für die elf berücksichtigten thermischen Zonen – Komfortband A: 21,5 °C bis 23,4 °C

Optimierung mittels:	2P-Regler	DMPC
Elektr. Energiebedarf der Wärmepumpe:	8924,3 kWh/a	5103,6 kWh/a
Kühlenergiebedarf TABS:	1834,4 kWh/a	1860,4 kWh/a
Heizenergiebedarf TABS:	26031,1 kWh/a	14164,0 kWh/a

Noch deutlicher fällt der Vorteil der prädiktiven Regelung beim erweiterten Komfortband B (21,8 °C bis 24,5 °C) aus (Tabelle 5). Der DMPC reduziert den elektrischen Energiebedarf der Wärmepumpe von 7486,5 kWh/a auf 4085,1 kWh/a, also um 45,4 %. Der Heizenergiebedarf der TABS sinkt von 22170,3 kWh/a auf 11858,4 kWh/a und damit um 46,5 %. Gleichzeitig verringert sich auch der Kühlenergiebedarf von 1165,0 kWh/a auf 904,0 kWh/a, entsprechend 22,4 %.

Tabelle 5: Gesamter Energiebedarf pro Jahr für die elf berücksichtigten thermischen Zonen – Komfortband B: 21,8 °C bis 24,5 °C

Optimierung mittels:	2P-Regler	DMPC
Elektr. Energiebedarf der Wärmepumpe:	7486,5 kWh/a	4085,1 kWh/a
Kühlenergiebedarf TABS:	1165,0 kWh/a	904,0 kWh/a
Heizenergiebedarf TABS:	22170,3 kWh/a	11858,4 kWh/a

Die Ergebnisse zeigen, dass der wesentliche Performancegewinn primär auf den prädiktiven Charakter des DMPC gegenüber der reaktiven Zweipunktregelung zurückzuführen ist. Besonders deutlich treten die Vorteile beim Heizenergiebedarf der TABS sowie beim elektrischen Energiebedarf der Wärmepumpe hervor. Dies deutet darauf hin, dass die prädiktive Regelung die thermische Speichermasse der aktivierten Bauteile effizienter nutzt und unnötige beziehungsweise gegenläufige Regelvorgänge reduziert.

4.3.3 Zusammenfassung ENERGETIKUM

Die Simulationsergebnisse für das ENERGETIKUM zeigen, dass die Wirkung der untersuchten Komfortbänder wesentlich von der eingesetzten Regelungsstrategie sowie von den verfügbaren gebäude- und anlagenseitigen Freiheitsgraden abhängt. Die festgelegten Komfortbänder sind nicht als ganzjährig uneingeschränkt aktiv regelbare Temperaturkorridore zu verstehen, sondern als Zielbereiche, deren tatsächliche Einhaltung von der jeweils verfügbaren thermischen Wirkrichtung abhängt.

Vor diesem Hintergrund übertrifft die DMPC-Variante den Zweipunktregler sowohl hinsichtlich der Temperaturführung als auch hinsichtlich des Jahresenergieverbrauchs deutlich. Während der Zweipunktregler ein stark schaltinduziertes und oszillierendes Verhalten aufweist, nutzt der DMPC den innerhalb der jeweiligen Saison verfügbaren Komfortbereich gezielter und ruhiger aus. Komfortabweichungen in die jeweils nicht aktiv kompensierbare Richtung bleiben jedoch auch beim DMPC prinzipiell möglich.

Energetisch ergeben sich klare Vorteile des prädiktiven Ansatzes. Gegenüber dem Zweipunktregler werden insbesondere der elektrische Energiebedarf der Wärmepumpe und der Heizenergiebedarf der TABS deutlich reduziert. Die größten Einsparungen zeigen sich beim breiteren Komfortband B, da dort zusätzliche thermische Freiheitsgrade zur Verfügung stehen. Begünstigt wird dies im ENERGETIKUM durch die Kombination aus großen Glasflächen, TABS und regelbarer Verschattung, wodurch neben der thermischen Speichermasse auch äußere Lasten aktiv beeinflusst werden können.

Insgesamt zeigen die Ergebnisse, dass ein Komfortband auch im ENERGETIKUM nur insoweit praktisch wirksam ist, wie es durch das Zusammenspiel von Regelung, TABS, Verschattung und saisonal verfügbarer Heiz- bzw. Kühlleistung tatsächlich umgesetzt werden kann.

4.3.4 Einhaltung des Komfortbandes LOWERGETIKUM

Abbildung 16 und Abbildung 17 zeigen die zeitlichen Verläufe der simulierten Raumlufttemperaturen der betrachteten Zonen im LOWERGETIKUM für die beiden untersuchten Regelungsstrategien Zweipunktregler und DMPC mit stündlicher Re-Optimierung. Die obere Teilgrafik bezieht sich jeweils auf Komfortband A (21,5 °C bis 23,4 °C), die untere auf Komfortband B (21,8 °C bis 24,5 °C). Rot hinterlegte Zeiträume kennzeichnen die Heizphase, blau hinterlegte die Kühlphase. In der Heizphase ist die Kühlung deaktiviert, in der Kühlphase die Heizung. Die Einhaltung der Komfortbänder ist daher nur innerhalb der verfügbaren Betriebsart zu beurteilen; Temperaturabweichungen in die jeweils entgegengesetzte Richtung können in diesen Zeiträumen nicht aktiv kompensiert werden.

Vor diesem Hintergrund zeigen die Verläufe, dass im LOWERGETIKUM insbesondere in der Kühlphase bei mehreren Zonen deutliche und teils länger anhaltende Unterschreitungen der unteren

Komfortgrenze auftreten. Diese Abweichungen sind daher nicht ausschließlich als Ausdruck unzureichender Regelgüte zu interpretieren, sondern auch als Folge der saisonalen Betriebsweise in Kombination mit der thermischen Trägheit des Gebäudes.

Zwischen den Regelungsstrategien sind Unterschiede erkennbar, diese fallen jedoch insgesamt geringer aus als beim ENERGETIKUM. Der Zweipunktregler weist das typische schaltinduzierte, stärker oszillierende Verhalten auf. Die DMPC-Variante führt zu einer geordneteren und etwas gleichmäßigeren Temperaturführung, ohne die grundsätzlichen Komfortabweichungen vollständig zu vermeiden. Daraus wird deutlich, dass die festgelegten Komfortbänder auch im LOWERGETIKUM nicht unabhängig von der konkreten Systemausstattung interpretiert werden dürfen.




Abbildung 16: Temperaturverläufe 2P-Regler (oben: Komfortband A; unten: Komfortband B) © Forschung Burgenland




Abbildung 17: Temperaturverläufe dezentraler DMPC mit stündlicher Re-Optimierung (oben: Komfortband A; unten: Komfortband B) © Forschung Burgenland

4.3.5 Jahresenergieverbrauch LOWERGETIKUM

Die Jahresenergiebedarfe (Tabelle 6) zeigen, dass die Unterschiede zwischen den Regelungsstrategien im LOWERGETIKUM insgesamt moderat ausfallen. Für Komfortband A reduziert der DMPC mit stündlicher Re-Optimierung gegenüber dem Zweipunktregler den elektrischen Energiebedarf der Wärmepumpe von 2807,0 kWh/a auf 2602,8 kWh/a, also um 7,3 %. Der Heizenergiebedarf der TABS sinkt von 12918,0 kWh/a auf 11915,7 kWh/a, entsprechend 7,8 %. Der Kühlenergiebedarf steigt hingegen leicht von 639,3 kWh/a auf 644,2 kWh/a, also um 0,8 %.

Tabelle 6: Gesamter Energiebedarf pro Jahr für die siebzehn berücksichtigten thermischen Zonen – Komfortband A: 21,5 °C bis 23,4 °C

Optimierung mittels:	2P-Regler	DMPC
Elektr. Energiebedarf der Wärmepumpe:	2807,0 kWh/a	2602,8 kWh/a
Kühlenergiebedarf TABS:	639,3 kWh/a	644,2 kWh/a
Heizenergiebedarf TABS:	12918,0 kWh/a	11915,7 kWh/a

Für Komfortband B ergibt sich ein ähnliches Bild (Tabelle 7). Der DMPC reduziert den elektrischen Energiebedarf der Wärmepumpe von 2841,0 kWh/a auf 2633,9 kWh/a, ebenfalls um 7,3 %. Der Heizenergiebedarf der TABS sinkt von 13530,1 kWh/a auf 12499,0 kWh/a, entsprechend 7,6 %. Der Kühlenergiebedarf steigt von 273,8 kWh/a auf 290,6 kWh/a, also um 6,1 %.

Tabelle 7: Gesamter Energiebedarf pro Jahr für die siebzehn berücksichtigten thermischen Zonen – Komfortband B: 21,8 °C bis 24,5 °C

Optimierung mittels:	2P-Regler	DMPC
Elektr. Energiebedarf der Wärmepumpe:	2841,0 kWh/a	2633,9 kWh/a
Kühlenergiebedarf TABS:	273,8 kWh/a	290,6 kWh/a
Heizenergiebedarf TABS:	13530,1 kWh/a	12499,0 kWh/a

Die im Vergleich zum ENERGETIKUM deutlich geringeren Unterschiede zwischen den Regelungsstrategien lassen sich vor allem durch die unterschiedliche Bauweise und Systemausstattung der beiden Gebäude erklären. Das ENERGETIKUM verfügt über große Glasflächen, TABS und eine regelbare Verschattung, sodass neben den thermischen Speichereffekten der aktivierten Bauteile auch die äußeren Lasten aktiv beeinflusst werden können. Im LOWERGETIKUM kommen zwar ebenfalls TABS zum Einsatz, es steht jedoch keine regelbare Verschattung zur Verfügung; der Verschattungswert bleibt über das gesamte Jahr konstant. Dadurch entfällt ein wesentlicher Stellhebel zur aktiven Beeinflussung solarer und äußerer Lasten. Die Regelung kann im Wesentlichen nur über die thermische Aktivierung der Bauteile wirken, was das Potenzial zusätzlicher Optimierungseffekte reduziert.

Der Vergleich der beiden Komfortbänder zeigt auch im LOWERGETIKUM eine systematische Verschiebung zwischen Heiz- und Kühlenergiebedarf. Der Übergang von Komfortband A zu Komfortband B reduziert bei beiden Regelungsstrategien den Kühlenergiebedarf, erhöht jedoch den Heizenergiebedarf. Das breitere beziehungsweise nach oben verschobene Komfortband erlaubt höhere Raumtemperaturen in der Kühlphase und senkt den Kühlbedarf, während die angehobene untere Komfortgrenze in der Heizphase einen höheren Heizbedarf verursacht. Im Jahresergebnis bleibt der elektrische Energiebedarf der Wärmepumpe dadurch jedoch nahezu unverändert. Die Wahl des Komfortbandes führt im LOWERGETIKUM daher vor allem zu einer Verschiebung zwischen Heiz- und Kühlanteilen, nicht jedoch zu einem grundlegenden energetischen Vorteil.

4.3.6 Zusammenfassung LOWERGETIKUM

Die Simulationsergebnisse für das LOWERGETIKUM zeigen, dass die Wirkung der untersuchten Komfortbänder wesentlich von den bauphysikalischen Eigenschaften des Gebäudes und den verfügbaren regelungstechnischen Freiheitsgraden abhängt. Ihre praktische Wirksamkeit hängt davon ab, wie gut sie durch das Gesamtsystem aus TABS, thermischer Speichermasse, saisonaler Betriebsweise und den verfügbaren Stellgrößen tatsächlich umgesetzt werden können.

Im Vergleich zum ENERGETIKUM fallen die energetischen Vorteile der prädiktiven Regelung im LOWERGETIKUM deutlich geringer aus. Dies ist vor allem darauf zurückzuführen, dass im LOWERGETIKUM zwar ebenfalls TABS, jedoch keine regelbare Verschattung vorhanden ist und zudem eine schwere Bauweise mit normal dimensionierten Fenstern vorliegt. Während im ENERGETIKUM somit sowohl die inneren thermischen Speicherwirkungen als auch die äußeren Lasten über die Verschattung aktiv beeinflusst werden können, beschränkt sich die Optimierung im LOWERGETIKUM im Wesentlichen auf die thermische Aktivierung der Bauteile. Entsprechend reduziert die DMPC-Variante den elektrischen Energiebedarf der Wärmepumpe und den Heizenergiebedarf nur moderat um etwa 7 bis 8 %.

Für die untersuchten Komfortbänder bedeutet dies, dass deren Potenzial im LOWERGETIKUM nur begrenzt durch die Regelung erschlossen werden kann. Ein festgelegtes Komfortband ist daher auch hier nur so gut, wie es durch die konkrete Kombination aus Gebäude, Anlagentechnik und Regelung tatsächlich umgesetzt werden kann.

Ergänzend ist festzuhalten, dass im gegenständlichen Projekt keine neuen methodischen Grundlagen entwickelt wurden, sondern bereits publizierte Ansätze und vorhandene Framework-Bausteine in einem klar abgegrenzten Untersuchungsrahmen zur Anwendung kamen. Dabei wurde die in „scaleFLEX“ implementierte und auf die Minimierung des Energiebedarfs ausgerichtete Zielfunktion als bestehender Baustein übernommen. Nicht Gegenstand der Untersuchungen waren hingegen eine kostenbasierte Optimierung, die Berücksichtigung unterschiedlicher Energiepreise sowie die Einbindung unterschiedlicher elektrischer Energiequellen in die Optimierung. Die dargestellten Ergebnisse beziehen sich somit ausschließlich auf den Einfluss der definierten Komfortbänder und der untersuchten Regelungsstrategien innerhalb der bestehenden methodischen Grundlagen. Zudem wurde im Projekt die Vergleichsbasis zwischen Zweipunktregler und DMPC methodisch präzisiert, indem die Komfortbänder für den Zweipunktregler in äquivalente Heiz- und Kühl-Sollwerte mit Hysterese überführt und für den DMPC direkt als Temperaturgrenzen des zulässigen Zustandsraums formuliert wurden. Damit konnte auch gezeigt werden, dass ein breiteres Komfortband nur dann energetisch wirksam genutzt werden kann, wenn die eingesetzte Regelung die dadurch entstehenden zusätzlichen Freiheitsgrade tatsächlich erschließt.

4.4 Replikationsstudie

Die bisherigen Kapitel haben gezeigt, dass die aus den Kohorten abgeleiteten Komfortbänder im PoC keinen eindeutigen Komfort-Effekt ergaben (Kapitel 4.2), in Kombination mit prädiktiver Regelung aber Energieeinsparungen ermöglichen (Kapitel 4.3). Offen blieb dabei die Frage, wie belastbar die zugrunde liegende Modellierungs-Methodik selbst ist. Die in Kapitel 3.2.6 beschriebene Reproduktionsstudie adressiert diese Frage.

Als Ausgangspunkt wurde untersucht, ob die erhobenen Merkmale überhaupt einen messbaren Zusammenhang mit der thermischen Komfortpräferenz aufweisen. Die Korrelationsanalyse auf den PersonAI-Daten zeigt, dass unter allen gemessenen Umgebungs- und physiologischen Features die Lufttemperatur mit einem Pearson-Korrelationskoeffizienten von $r = 0,45$ die stärkste Assoziation zur Komfortklasse aufweist (Abbildung 18). Physiologische Signale wie die Herzfrequenz zeigen dagegen nahezu keinen Zusammenhang ($r = 0,024$). Bei den aus der Onboarding-Befragung gewonnenen psychologischen und demografischen Features sind die Korrelationen durchwegs schwach; den höchsten Wert erreicht mit $r = 0,23$ die Persönlichkeitsdimension „Offenheit“. Diese Befunde decken sich mit den explorativen Analysen aus der Datenaufbereitung und deuten bereits vor der Modellevaluation darauf hin, dass die verfügbaren Merkmale nur eingeschränkt geeignet sind, die individuelle Komfortpräferenz vorherzusagen.




Abbildung 18: Korrelationsanalyse - PersonAI © TU Wien

Bei Verwendung von F1-Micro, der im Originalpaper eingesetzten Metrik, lassen sich die dort berichteten Ergebnisse auf dem Dorn-Datensatz weitgehend reproduzieren. Die Modelle erreichen Werte um 0,77. F1-Macro, das die Klassifikationsleistung über alle drei Komfortklassen gleichmäßig gewichtet, zeigt hingegen, dass die Werte aller Modelle in der Nähe einer Mehrheitsklassen-Vorhersage liegen. Die unter F1-Micro scheinbar gute Leistung beruht im Wesentlichen auf der korrekten Vorhersage der dominanten Klasse „Keine Veränderung“. Auf dem PersonAI-Datensatz ist dieser Effekt noch deutlicher erkennbar. Der Random Forest erzielt hier einen F1-Micro von 0,76, genau den Wert, den auch eine triviale „immer No Change“-Vorhersage erreicht.

Der Grund liegt in der bereits in Kapitel 4.1 beschriebenen Klassen-Imbalance, die auch im Dorn-Datensatz in vergleichbarer Form auftritt (Abbildung 19). Unter diesen Bedingungen genügt es, stets die häufigste Klasse vorherzusagen, um unter F1-Micro einen hohen Wert zu erzielen.




Abbildung 19: Klassenverteilung - Dorn vs. PersonAI © TU Wien

Die Konfusionsmatrizen bestätigen dieses Verhalten. Sowohl das Baseline-Modell als auch der Random Forest präzisieren den überwiegenden Teil der Datenpunkte als „Keine Veränderung“, während die Klassen „Kühler“ und „Wärmer“ kaum korrekt erkannt werden (Abbildung 20).




Abbildung 20: Konfusionsmatrix - Dorn Datensatz © TU Wien

Besonders deutlich wird der Effekt bei Teilnehmer:innen mit nahezu homogenem Antwortmuster. Für eine Person im Dorn-Datensatz die beinahe ausschließlich „Keine Veränderung“-Antworten gibt, erreicht das PCM unter F1-Micro einen hohen Wert, obwohl es ausschließlich die Mehrheitsklasse vorhersagt (Abbildung 21).




Abbildung 21: Konfusionsmatrix - Einzelner Teilnehmer aus dem Dorn Datensatz © TU Wien

Abbildung 22 und Abbildung 23 zeigen die Vorhersageleistung der verschiedenen Modellansätze auf dem Dorn- bzw. dem PersonAI-Datensatz, jeweils aufgeschlüsselt nach F1-Micro und F1-Macro. Unter F1-Micro liegen alle Ansätze (PCM, Warm Start, Cold Start, Cohort Baseline, Majority) auf vergleichbarem Niveau. Die Boxplots überlappen sich teilweise stark, was darauf hindeutet, dass keiner der Modellansätze einen konsistenten Vorteil gegenüber der simplen Mehrheitsklassen-Vorhersage erzielt. Unter F1-Macro sinkt die Leistung aller Ansätze deutlich ab. Auf dem Dorn-Datensatz erreichen die PCMs unter F1-Macro noch einen medianen Wert von rund 0,50, während die übrigen Ansätze bei etwa 0,30 liegen. Auf dem PersonAI-Datensatz zeigt sich ein ähnliches Muster mit einem PCM-Median von rund 0,40 gegenüber etwa 0,30 bei den übrigen Ansätzen.




Abbildung 22: Vergleich Vorhersageleistungen - Dorn Datensatz © TU Wien




Abbildung 23: Vergleich Vorhersageleistungen - PersonAI Datensatz © TU Wien

Ob die Zuordnung zu einer passenden Kohorte die Vorhersageleistung tatsächlich verbessert, wurde zusätzlich über den Vergleich von korrekter und absichtlich falscher Kohortenzuordnung getestet. Nur ein einziger der untersuchten Kohorten-Ansätze schneidet bei korrekter Zuordnung geringfügig besser ab. Bei allen anderen Varianten liefert die falsche Zuordnung gleich gute oder sogar bessere Ergebnisse.

Eine nähere Analyse zeigt zudem, dass die in der Originalpublikation berichteten Leistungsgewinne der Cohort-Modelle in beiden dort verwendeten Datensätzen auf wenige Ausreißer zurückgehen, typischerweise zwei bis vier Personen, deren Antworten fast ausschließlich einer einzigen Komfortklasse zuzuordnen sind (z. B. 97 % „Kühler“- bzw. 97 % „Keine Veränderung“-Antworten). Für diese Personen ergibt sich ein rechnerisch großer Performancegewinn, der jedoch primär auf der trivialen Vorhersagbarkeit ihres Antwortmusters beruht. Für alle übrigen Teilnehmer:innen liegt die Leistungsveränderung durch die Kohortenzuordnung nahe null oder darunter.

Die Annahme, dass 60 Datenpunkte pro Person für eine stabile Komfortvorhersage ausreichen, stammt von Kim et al. (2018). Das dort verwendete Konvergenzkriterium, bei dem die Ableitung einer Lernkurve über zwei aufeinanderfolgende Durchläufe innerhalb von $\pm 0,001$ stagniert, beschreibt allerdings keinen Konvergenzbegriff im mathematischen Sinn. Es identifiziert Sattelpunkte oder lokale Extrema. In den eigenen Abbildungen der Autoren finden sich Personen mit fünf oder mehr solcher „Konvergenzen“. Dass die Modelle bei 60 Datenpunkten scheinbar ausreichend performen, liegt weniger an einem tatsächlich gelernten Zusammenhang als daran, dass sie die Mehrheitsklassenverteilung reproduzieren.

Die Reproduktionsstudie liefert damit keine Belege dafür, dass Cohort Comfort Models die Vorhersage gegenüber einer einfachen Baseline verbessern. Die Originalergebnisse auf dem Dorn-Datensatz ließen sich unter F1-Micro reproduzieren, zeichnen unter F1-Macro aber ein schwächeres Bild. Auf dem PersonAI-Datensatz ist das noch deutlicher.

4.5 Innovationen & Highlights

Im Rahmen des Projekts wurde eine der umfangreichsten longitudinalen Komforterhebungen in einer europäischen Klimazone durchgeführt: 83 Teilnehmer:innen über vier Wochen, mit paralleler Erfassung von Umgebungsdaten, physiologischen Signalen und wiederholten Komfortbefragungen unter realen Alltagsbedingungen.

Auf dieser Datenbasis wurde die publizierte Codebasis der Cohort Comfort Models nach Quintana et al. (2023) erstmals auf einem unabhängigen europäischen Datensatz angewendet. Die daraus abgeleiteten Temperatur-Sollwerte wurden im Proof of Concept erstmals in einem realen Gebäude als Setpoints implementiert. Das dabei eingesetzte Validierungs-Setup mit bewusst falscher Kohortenzuordnung ermöglichte eine methodisch saubere Unterscheidung zwischen Kohorten-Effekt und unspezifischen Einflussfaktoren.

Parallel dazu quantifizierten die Energiesimulationen erstmals die Wirkung kohortenbasierter Komfortbänder in Kombination mit modellprädiktiver Regelung an zwei Gebäuden mit unterschiedlicher Bauweise und Anlagentechnik und wiesen Einsparungen von 7 bis 47 % nach.

Die im Anschluss an das PoC durchgeführte Reproduktionsstudie auf den Originaldaten und dem PersonAI-Datensatz identifizierte ein Information Leak in der Referenz-Codebasis, wies nach, dass F1-Micro als Bewertungsmetrik bei unbalancierten Komfortdaten ungeeignet ist und stellte die Annahme in Frage, dass 60 Datenpunkte pro Person für stabile Komfortvorhersagen ausreichen.

4.6 Einpassung in den Schwerpunkt „Klimaneutrale Stadt“

Das Projekt PersonAI ordnet sich in den Themenbereich „Klimaneutrale Gebäude und Quartiere“ des Schwerpunkts „Klimaneutrale Stadt“ ein. Gebäude verursachen rund 40 % des Endenergieverbrauchs und 36 % der CO₂-Emissionen in der EU und sind damit ein zentraler Hebel auf dem Weg zur Klimaneutralität. Der Schwerpunkt verfolgt das Ziel, durch Forschung und Entwicklung praxistaugliche Lösungen zu schaffen, die den Energieverbrauch im Gebäudesektor senken und gleichzeitig Lebensqualität und Gesundheit der Bewohner:innen sicherstellen. PersonAI adressiert beide Seiten dieser Anforderung: die technische Frage, wie Gebäude energieeffizienter betrieben werden können, und die menschliche Frage, wie dabei individuelle Komfortbedürfnisse berücksichtigt werden können.

Die empirische Erhebung schließt eine Lücke in der bisherigen Forschungslandschaft, die überwiegend auf tropische Klimazonen und kontrollierte Laborsettings beschränkt war. PersonAI liefert Daten aus realen Alltagsbedingungen in einem mitteleuropäischen Gebäudebestand und schafft damit eine breitere Grundlage für menschenzentrierte Energieservices im europäischen Kontext. Der Datensatz ermöglicht es zudem, genderspezifische und andere Diversity-Aspekte im thermischen Komfort sichtbar zu machen.

Die Energiesimulationen liefern konkrete Zahlen zum Zusammenspiel von Energieeffizienz und Nutzer:innenkomfort. Dass die Einsparungen primär aus der Regelungsstrategie resultieren, ist dabei eine für die praktische Umsetzung relevante Erkenntnis: Prädiktive Regelungsverfahren können auch ohne funktionierende individuelle Komfortmodelle erhebliche Wirkung haben, sofern Gebäudetyp und Anlagentechnik die nötigen Freiheitsgrade bieten.

Die Reproduktionsstudie zeigt, dass datengetriebene Methodik vor einer Überführung in die Gebäudepraxis einer unabhängigen Überprüfung bedarf. Für die im Schwerpunkt angestrebte Skalierung auf Quartiersebene ist das eine wesentliche Voraussetzung, da nicht belastbare Modelle im Realbetrieb kontraproduktiv sein können.

Darüber hinaus leistet das Projekt einen Beitrag zur interdisziplinären Vernetzung. PersonAI vereint Softwaretechnologie, Gebäudetechnik, Psychologie und Rechtswissenschaften in einem Konsortium. Die rechtliche Analyse hat gezeigt, dass nutzer:innenzentrierte Energieservices nur dann nachhaltig umsetzbar sind, wenn Datenschutz, Technologievertrauen und technisches Systemdesign von

Anfang an gemeinsam erarbeitet werden. Diese Erkenntnis ist für alle Vorhaben relevant, die personenbezogene Daten in Smart-Building-Anwendungen verarbeiten.

Die gewonnenen Erkenntnisse sind somit auf andere Gebäudetypen und Städte übertragbar und unterstützen damit das übergeordnete Ziel, praxistaugliche und skalierbare Lösungen für klimaneutrale Gebäude und Quartiere zu entwickeln.

5 Schlussfolgerungen

Die zentralen Projektergebnisse und Innovationen sind in den Kapiteln 4.1 bis 4.5 dokumentiert. Im Folgenden werden die daraus abgeleiteten Schlussfolgerungen für das Projektteam und die Weiterarbeit dargestellt.

Eine der wichtigsten methodischen Erkenntnisse betrifft den Umgang mit publizierter Forschungssoftware. Das Projekt baute bewusst auf der Codebasis und Methodik von Quintana et al. (2023) auf, um auf einer bereits validierten Grundlage zu arbeiten. Im Verlauf der Arbeit zeigte sich jedoch, dass diese Grundlage selbst einer Überprüfung bedurfte. Die daraus entstandene Reproduktionsstudie war ursprünglich nicht geplant, erwies sich aber als einer der ergiebigsten Arbeitsstränge des Projekts. Für das Projektteam bekräftigt diese Erfahrung, dass bei datengetriebenen Methoden nicht nur die berichteten Ergebnisse, sondern auch die Evaluierungsstrategie, die verwendeten Metriken und die Datenverarbeitung unabhängig geprüft werden müssen, bevor darauf aufgebaut wird.

Die zweite wesentliche Erkenntnis betrifft die Frage, wo das tatsächliche Einsparpotenzial im Gebäudebetrieb liegt. Die Energiesimulationen haben gezeigt, dass die wesentlichen Einsparungen aus der prädiktiven Regelungsstrategie (DMPC) und den damit erschlossenen thermischen Freiheitsgraden resultieren, nicht aus der Personalisierung der Komfortmodelle. Auf der Komfortseite ließ sich im PoC kein eindeutiger Vorteil der kohortenbasierten Sollwertsteuerung gegenüber dem regulären Gebäude-Setpoint nachweisen. Die Reproduktionsstudie stützt diesen Befund, indem sie zeigt, dass sich auch auf dem umfangreicheren Referenzdatensatz kein statistisch belastbarer Leistungsunterschied zwischen den CCM und einer einfachen Baseline feststellen lässt. Welche Rolle kohortenbasierte oder individuelle Komfortmodelle in zukünftigen Ansätzen spielen können und unter welchen Datenbedingungen sie einen tatsächlichen Mehrwert bieten, bleibt eine offene Forschungsfrage, die in den laufenden und geplanten Folgeprojekten des Konsortiums weiter untersucht wird (siehe Kapitel **Fehler! Verweisquelle konnte nicht gefunden werden.**).

Die rechtliche Analyse im Projekt hat gezeigt, dass die im Projekt entwickelten Konzepte zu Personal bzw. Cohort Comfort Models nicht nur technisch, sondern vor allem datenschutzrechtlich anspruchsvoll sind. Die zentrale Herausforderung liegt darin, dass die eingesetzten Technologien (Wearables, Umweltsensoren und Befragungen) keine bloß technischen Betriebsdaten erzeugen, sondern Daten, die einzelnen Personen zugeordnet werden können. Im Ergebnis unterfallen die im Projekt erhobenen Daten insgesamt dem Anwendungsbereich der DSGVO; ein wesentlicher Teil ist zudem als Gesundheitsdaten einzuordnen und unterliegt damit den erhöhten Anforderungen des Art. 9 DSGVO. Besonders relevant ist die Erkenntnis, dass auch scheinbar harmlose oder rein technische Daten rechtlich sensibel werden können, sobald sie mit anderen Datenquellen kombiniert werden. Das betrifft etwa Umfragedaten zu thermischem Empfinden oder Stimmung, die in Verbindung mit physiologischen Messwerten Rückschlüsse auf körperliches oder psychisches Wohlbefinden zulassen können. Auch Raum- und CO₂-Sensordaten können im konkreten Nutzungskontext

personenbezogen sein, etwa wenn sie Anwesenheit oder Nutzungsmuster in kleinen Büros erkennen lassen und mit Wearable- oder Umfragedaten zusammengeführt werden. Für die praktische Weiterentwicklung bedeutet dies, dass Datenschutz nicht als nachgelagerte Compliance-Frage behandelt werden kann. Vielmehr müssen Datenminimierung, Zweckbindung, Pseudonymisierung, Zugriffsbeschränkungen, transparente Information der Nutzer:innen und klare Verantwortlichkeiten bereits im technischen Design berücksichtigt werden. Die im Projekt eingesetzte Pseudonymisierung reduziert Risiken, führt aber nicht dazu, dass die Daten außerhalb der DSGVO stehen, da über Teilnehmer:innen-Codes, Zeitstempel und zusammengeführte Datensätze weiterhin eine Zuordnung möglich bleibt.

Die Haupteckensteine aus rechtlicher Sicht sind daher:

- **PersonAI verarbeitet nicht nur Komfortdaten, sondern rechtlich relevante personenbezogene und teilweise sensible Daten.** Das betrifft insbesondere physiologische Daten aus Wearables, aber auch Kontext- und Befragungsdaten.
- **Raumsensordaten sind nicht automatisch unproblematische Sachdaten.** CO₂-, Temperatur- oder Luftfeuchtigkeitsdaten können durch Kontext, geringe Nutzer:innenzahl und Datenverknüpfung personenbezogen werden.
- **Pseudonymisierung ist notwendig, aber nicht ausreichend.** Sie senkt das Risiko, ersetzt aber keine Rechtsgrundlage, keine Zweckbindung und keine technischen-organisatorischen Schutzmaßnahmen.

Zusammengefasst bestehen die wichtigsten rechtlichen Hürden in der DSGVO-Pflichtigkeit der gesamten Datenverarbeitung, dem hohen Schutzbedarf von Gesundheits- und Kontextdaten, der fehlenden echten Anonymisierung, dem Re-Identifizierungsrisiko durch Datenverknüpfung, der Komplexität der beteiligten Plattformen und Schnittstellen sowie der Notwendigkeit, Vertrauen, Transparenz und Freiwilligkeit sicherzustellen. Für die Weiterentwicklung der PersonAI-Konzepte bedeutet das: Datenschutz, Datenminimierung, Zweckbindung, Rollenklärung, sichere Pseudonymisierung und nutzer:innenverständliche Einwilligungs- bzw. Informationsprozesse müssen als Kernbestandteile der Technologieentwicklung behandelt werden und nicht als nachgelagerte Compliance-Fragen.

Diese o.g. Erkenntnisse, insbesondere aus der rechtlichen Perspektive wurden im Konsortium bereits in Follow-Up-Projekten berücksichtigt. Die rechtliche Analyse macht deutlich, dass nutzer:innenzentrierte Energy Services nur dann nachhaltig umsetzbar sind, wenn Datenschutz, Technologievertrauen und technisches Systemdesign gemeinsam gedacht werden. Um von einem grundlagentnahen Forschungsprojekt zu einem skalierbaren Produkt zu reifen, müssen drei zentrale Hürden überwunden werden:

- **Datenschutz (DSGVO):** Die Erfassung individueller Komfortpräferenzen (Personal Comfort Models) über Wearables stößt auf massive Widerstände bei Betriebsräten.
- **Technischer Integrationsaufwand:** Die heterogene TGA-Landschaft (BACnet, KNX, proprietäre Systeme) erfordert standardisierte APIs, um die Onboarding-Kosten (CAPEX) pro Gebäude niedrig zu halten.
- **Haftungsfragen:** Ein aktiver Eingriff in die Gebäudesteuerung wirft Fragen der Betriebsverantwortung (z.B. bei Schimmelbildung durch KI-Fehlsteuerung) auf.

Grundsätzlich sind die Projektergebnisse aus drei Perspektiven relevant: erstens für technische Folgeentwicklungen und Proof-of-Concepts in Gebäudeautomation und Energy Services, zweitens für wissenschaftliche Anschlussarbeiten zu robusten, reproduzierbaren und dateneffizienten Komfortmodellen, und drittens für rechtliche und organisatorische Leitlinien zur datenschutzkonformen Umsetzung nutzer:innenzentrierter Smart-Building-Anwendungen. Die Ergebnisse sind daher für mehrere Zielgruppen relevant (siehe Tabelle 8). Die Tabelle zeigt einen Überblick über die identifizierten Stakeholdergruppen, die spezifische Projektrelevanz und den Ausblick und mögliche Weiterarbeiten mit den Ergebnissen.

Tabelle 8: Relevanz der Ergebnisse für Zielgruppen

Identifizierte Zielgruppen	Relevanz	Ausblick und Weiterarbeit
Energiedienstleister und Anbieter innovativer Energy Services	Besonders relevant sind die Erkenntnisse dazu, welche Daten für Komfortvorhersagen sinnvoll erhoben werden können, welche methodischen Grenzen bei der Modellierung bestehen und welche rechtlichen Anforderungen bei personenbezogenen und sensiblen Daten zu beachten sind.	Bestehende Services wie Demand Response, modellprädiktive Regelung, Optimierung, Fehlererkennung oder Predictive Maintenance stärker nutzer:innenzentriert ausrichten; Neue Geschäftsmodelle, Beratungsleistungen oder Servicekonzepte
Unternehmen der Gebäudeautomation, Gebäudetechnik und Facility-Management	Relevant, wie PCM- oder CCM-Ansätze in bestehende Gebäudeleittechnik, Regelzonen und Schnittstellen eingebunden werden könnten.	Energiesimulationen zeigten, dass die aus den Kohorten abgeleiteten Komfortbänder in Verbindung mit einer modellprädiktiven Regelung (DMPC) Energieeinsparpotenzial bieten

Identifizierte Zielgruppen	Relevanz	Ausblick und Weiterarbeit
Energie- und IoT-Dienstleister	Für Anbieter datengetriebener Energy Services sind semantische Metadaten eine zentrale Voraussetzung für Skalierbarkeit.	Entwicklung und automatisierte Ausrollung von Energy Services (z. B. FDD, Predictive Control); Nutzung der Ontologien als einheitliche Schnittstelle für verschiedene Gebäude; Reduktion projektspezifischer Anpassungen und manueller Konfiguration; Beschleunigte Markteinführung neuer Services
Hardware-Hersteller, Sensorik-Anbieter und Softwareentwickler:innen	Stakeholder können aus PersonAI ableiten, welche technischen und rechtlichen Anforderungen für nutzer:innen-zentrierte Komfortdienste bestehen. Für Hersteller ist daraus ableitbar, welche Datenflüsse, Schnittstellen, Datenqualitätsanforderungen und Usability-Anforderungen bei solchen Anwendungen besonders wichtig sind.	Privacy-by-Design, Pseudonymisierung, Datenminimierung und transparente Einwilligungsprozesse dürfen nicht nachgelagert sein, sondern integraler Teil des Produktdesigns sein
Forschungseinrichtungen und die wissenschaftliche Community	Die Projektergebnisse stellen methodische, datenbezogene und softwareseitige Beiträge zum Stand der Forschung dar (empirischen Daten, das Studiendesign und die Erfahrungen mit Datenerhebung im Feld; die kritische Auseinandersetzung mit Cohort Comfort Models, Modellvalidierung, Trainingsdatenbedarf und Reproduzierbarkeit.)	PersonAI liefert damit eine Grundlage für weitere Studien zu robusteren Komfortmodellen, für Vergleiche unterschiedlicher ML-Verfahren, für bessere Evaluationsmetriken und für die Frage, unter welchen Bedingungen individuelle oder gruppenbasierte Komfortmodelle tatsächlich verlässliche Vorhersagen ermöglichen; Nutzung der offenen Datensätze und Open-Source-Komponenten; Anschlussprojekte; Integration in Lehre, Abschlussarbeiten und Dissertationen

Identifizierte Zielgruppen	Relevanz	Ausblick und Weiterarbeit
Policy Maker, Verwaltung und Regulierungsakteure	Für politische Entscheidungsträger:innen und Förderstellen sind die Ergebnisse relevant, da sie praktische Lösungsansätze zur Umsetzung von Klimazielen liefern.	Unterstützung evidenzbasierter Energie- und Gebäudepolitik; Skalierung von Digitalisierungs- und Sanierungsprogrammen; Bewertung von Technologiepotenzialen für klimaneutrale Städte; Ableitung von Standards und Leitlinien für interoperable Gebäudedaten
Jurist:innen, Datenschutzbeauftragte und Compliance-Verantwortliche	Rechtliche Analyse kann als Orientierung für ähnliche Projekte im Bereich Smart Buildings, Wearables und nutzer:innen-zentrierte Energieservices verwendet werden. Besonders wichtig ist die Einordnung, dass im Projekt verarbeitete Daten insgesamt in den Anwendungsbereich der DSGVO fallen und ein wesentlicher Teil als Gesundheitsdaten besonderen Schutzanforderungen nach Art. 9 DSGVO unterliegt.	Anhaltspunkte für Einwilligungsmanagement, Rollenverteilung zwischen Verantwortlichen und Auftragsverarbeitern, Datenminimierung, Pseudonymisierung, Speicher- und Zugriffskonzepte sowie die Bewertung von Re-Identifizierungsrisiken

Zusätzlich sind die Ergebnisse auch für Endnutzer:innen und Gebäudenutzer:innen relevant. Sie sind schließlich nicht nur Datenquellen, sondern eine zentrale Zielgruppe der Anwendung. Das Projektteam ist der Meinung, dass nutzer:innenzentrierte Komfortmodelle langfristig zu besser abgestimmtem Innenraumklima, höherem Komfort und größerer Akzeptanz von Energieeffizienzmaßnahmen beitragen können. Gleichzeitig zeigen die Projektergebnisse, dass Nutzer:innenvertrauen nur entsteht, wenn klar ist, welche Daten erhoben werden, wofür sie verwendet werden, welche Vorteile daraus entstehen und welche Schutzmaßnahmen greifen.

Darauf aufbauend steht der Markt für Indoor Climate Management vor einem Paradigmenwechsel. Getrieben durch strenge regulatorische Vorgaben und steigende Energiepreise wandelt sich die Nachfrage von reinen passiven Monitoring-Lösungen hin zu aktiven, KI-gesteuerten Regelungssystemen.

Der Markt wird durch klare europäische Fristen zum Handeln gezwungen.

- **EPBD 2024/1275:** Bis Mai 2026 müssen Mitgliedsstaaten nationale Standards für Indoor Environmental Quality (IEQ) festlegen (Artikel 13). Ab 2030 werden Monitoring- und Kontrollsysteme für neue Nichtwohngebäude verpflichtend (Europäisches Parlament & Rat der EU, 2024)¹
- **CSRD & EU-Taxonomie:** Nichtfinanzielle Berichterstattung (ESRS S1/S4) erzwingt zunehmend den Nachweis gesunder Arbeitsumgebungen, was IEQ-Monitoring zu einer Compliance-Anforderung für das Real-Estate-Portfolio-Management macht (EFRAG, 2023)²

Der adressierbare Markt ist signifikant, muss jedoch nach Integrationsfähigkeit gefiltert werden.

- **Bestand an Nichtwohngebäuden:** In Deutschland liegt die beheizte Fläche von funktional relevanten Nichtwohngebäuden laut Datenerhebungen bei ca. 2,7 bis 3,0 Milliarden m² (Hörner & Knissel, 2023)³. Für den gesamten DACH-Raum wird die Fläche konservativ auf **ca. 3,5 Milliarden m²** geschätzt.
- **Theoretisches Marktpotenzial (TAM):** Legt man einen branchenüblichen Benchmark-SaaS-Preis von **1,50 €/m²/Jahr** zugrunde (abgeleitet von SaaS-Preismodellen für ESG- und ICM-Software wie Freesi, die bei ca. 0,12 €/m²/Monat liegen⁴), beläuft sich das Gesamtpotenzial (TAM) im DACH-Raum auf rund **5,25 Milliarden Euro jährlich**.
- **Adressierbarer Markt (SAM):** Realistisch sind primär professionell gemanagte Flächen (Büros, Gesundheit, Bildung) mit bestehender Gebäudeautomation und hohem ESG-Druck. Geht man von **25 % des Bestands** aus (eigene marktspezifische Annahme für das Premium- und digitalisierbare Segment), ergibt sich ein initiales Marktvolumen von ca. **1,3 Milliarden Euro jährlich** (DACH).
- **Fokus-Zielgruppen:** Premium-Büroimmobilien (Corporate Real Estate) bieten die höchste Zahlungsbereitschaft. Bildungseinrichtungen und Gesundheitsbauten weisen einen hohen Leidensdruck auf, sind aber durch Vergabeprozesse langsamer in der Adaption.

Das Marktpotenzial für PersonAI ist unserer Meinung nach groß und wächst durch den regulatorischen Druck der EPBD rasant. Der kommerzielle Erfolg hängt maßgeblich davon ab, ob die Lösung als datenschutzkonforme, leicht integrierbare Software-Schnittstelle (API) zu positionieren ist, die

¹ Spezifisch: Artikel 13 zur Festlegung nationaler Standards für die Raumluftqualität (IEQ) bis 2026 und Ausrüstungspflichten für Nichtwohngebäude ab 2030.

² Die Standards ESRS S1 (Eigene Belegschaft) und S4 (Verbraucher und Endnutzer) verlangen Angaben zu Maßnahmen für Gesundheit und Sicherheit, worunter Raumluftqualität und Arbeitsbedingungen in Gewerbeimmobilien fallen.

³ Mit einem Aufschlag für Österreich und die Schweiz (etwa 15–20 % der deutschen Wirtschaftsleistung) ergibt sich der Schätzwert von ca. 3,5 Milliarden m² für den DACH-Raum.

⁴ Preis-Benchmark (1,50 €/m²/Jahr): Plausibilisierte Annahme auf Basis von Preisstrukturen existierender PropTechs. Anbieter von Indoor Climate & ESG-Reporting-Software (wie z. B. Freesi) operieren oft in einer Preis-Range von rund 0,10 bis 0,15 € pro m² pro Monat (entspricht ca. 1,20 € bis 1,80 € pro Jahr). Dieser Wert dient als konservativer Näherungswert für das adressierbare finanzielle Volumen.

bestehenden passiven Systeme zu aktiven Regelkreisen aufwertet. Vom Konsortium wurde das Marktpotential laufend mit dem Green Energy Lab evaluiert und abschließend drei nächste Schritte für einen erfolgreichen Markteintritt definiert:

- **Pivot zu Cohort Models:** Der Fokus des Minimum Viable Products (MVP) muss so wie im Proof of Concept von rein personenbezogenen Modellen auf zonen- oder gruppenbasierte Modelle („Cohort Models“) verschoben werden, um DSGVO-Barrieren drastisch zu senken.
- **Partner-First-Strategie:** Ein eigener Direktvertrieb ist ineffizient. PersonAI sollte als Software-Lizenz (API) für bestehende PropTechs, BMS-Hersteller oder Monitoring-Plattformen (wie Freesi) vertrieben werden.
- **Beweisführung außerhalb des Labors:** Der entscheidende Meilenstein nach dem „Energetikum“-PoC ist der Nachweis der „Plug-and-Play“-Fähigkeit in einem handelsüblichen, drittverwalteten Bestandsgebäude. Wichtigste KPIs hierfür sind Reduktion der HVAC-Energie, Anzahl reduzierter „Hot/Cold-Calls“ beim Facility Management und die Dauer des System-Onboardings in Personentagen.

Abschließend zeigte sich die interdisziplinäre Perspektive von PersonAI als besonders wertvoll. Das Projekt zeigte nicht nur, was technisch möglich ist, sondern auch, welche methodischen, praktischen und rechtlichen Voraussetzungen erfüllt sein müssen, damit personalisierte Komfortmodelle verantwortungsvoll weiterentwickelt und angewendet werden können.

6 Ausblick und Empfehlungen

Aus den Projektergebnissen lassen sich Empfehlungen für drei Bereiche ableiten: die Weiterentwicklung der Komfortmodellierung, die energetische Nutzung von Komfortbändern in der Gebäuderegelung und die Überführung der Erkenntnisse in weiterführende Forschungs- und Demonstrationsvorhaben.

Komfortmodellierung und Datenerhebung

Aufbauend auf den in der Reproduktionsstudie identifizierten offenen Punkten ergeben sich mehrere Ansatzpunkte für weiterführende Arbeiten. Zukünftige Studien sollten einen Erhebungszeitraum über mehrere Jahreszeiten vorsehen, um die saisonale Varianz in den Komfortantworten zu erhöhen. Darüber hinaus wäre zu untersuchen, ob alternative Erhebungsdesigns, etwa kontextadaptive Befragungsstrategien, die gezielt in thermisch auffälligen Situationen triggern, die Besetzung der Minderheitsklassen verbessern können. Auch die Frage, welche physiologischen und kontextuellen Merkmale tatsächlich prädiktiv für thermische Präferenzen sind und welche primär personenbezogene Varianz abbilden, ist auf Basis der vorliegenden Daten nicht abschließend beantwortet und erfordert weitere Untersuchung.

Komfortbänder und Gebäuderegelung

Ein wesentliches Ergebnis des Projekts ist, dass Komfortbänder nicht isoliert betrachtet werden können, sondern nur im Zusammenhang mit der tatsächlich verfügbaren Regelungs- und Anlagentechnik ihre Wirkung entfalten. Weiterführende Arbeiten sollten daher untersuchen, nach welchen Kriterien Komfortbänder so festgelegt werden können, dass sie thermisch angemessen und regelungstechnisch realistisch umsetzbar sind. Dabei sind Gebäudetyp, thermische Speichermasse, Fensterflächen, solare Lasten, Verschattung sowie die verfügbare Heiz- und Kühlleistung zu berücksichtigen. Das Komfortband sollte zukünftig nicht nur als feste Randbedingung, sondern als eigenständiger Optimierungsparameter betrachtet werden. In diesem Zusammenhang wäre systematisch zu analysieren, in welchen Bereichen eine Erweiterung oder Verschiebung des Komfortbandes energetische Vorteile ermöglicht und ab wann Komforteinbußen oder regelungstechnische Restriktionen überwiegen.

Folgeprojekte und Demonstrationsvorhaben

Mehrere der im Projekt aufgeworfenen Fragen werden in laufenden und geplanten Vorhaben weiterverfolgt. Im Projekt WellFit wird das Studiendesign von PersonAI bei sommerlichen Temperaturen repliziert und erweitert, um die saisonale Lücke der bisherigen Erhebung zu schließen. Im Rah-

men eines geplanten Stadtprojekts (URBAN) sollen die Ansätze auf Quartiersebene übertragen werden. Weitere Vorhaben befassen sich mit der Verbindung von Innenraumluftqualität und Wearable-Daten, um das Zusammenspiel von Komfort und Gesundheit besser zu verstehen.

Die wissenschaftliche Zusammenarbeit mit dem Advisory Board, Stefano Schiavon (University of California Berkeley) und Clayton Miller (National University of Singapore), wird fortgesetzt. Gemeinsam sind Publikationen in Vorbereitung, unter anderem zur Frage, wie sich Wearable-gestützte Studien technisch und organisatorisch in größerem Maßstab umsetzen lassen, sowie eine Übersichtsarbeit zum Zusammenhang zwischen subjektivem Komfortempfinden und objektiv gemessenen Raumparametern.

Für ein Demonstrationsvorhaben wäre der nächste Schritt die Erprobung der im Projekt entwickelten Ansätze in einem handelsüblichen, drittverwalteten Bestandsgebäude. Die wesentliche Herausforderung liegt dabei im Übergang von den kontrollierten Bedingungen der Living Labs zu einer heterogenen technischen Gebäudeinfrastruktur mit unterschiedlichen Automationssystemen und Schnittstellen. Die im Projekt gewonnenen Erkenntnisse zu Datenqualität, methodischen Grenzen und datenschutzrechtlichen Anforderungen bilden eine fundierte Grundlage für die Planung und Umsetzung solcher Vorhaben.

Tabellenverzeichnis

Tabelle 1: Mittlere Komforttemperaturen der Cold-Start-Kohorten	36
Tabelle 2: Mittlere Komforttemperaturen der Warm-Start-Kohorten	37
Tabelle 3: Finale Kohorten für das Proof of Concept mit Sollwerten und Komfortbändern	37
Tabelle 4: Gesamter Energiebedarf pro Jahr für die elf berücksichtigten thermischen Zonen – Komfortband A: 21,5 °C bis 23,4 °C	42
Tabelle 5: Gesamter Energiebedarf pro Jahr für die elf berücksichtigten thermischen Zonen – Komfortband B: 21,8 °C bis 24,5 °C	42
Tabelle 6: Gesamter Energiebedarf pro Jahr für die siebzehn berücksichtigten thermischen Zonen – Komfortband A: 21,5 °C bis 23,4 °C	45
Tabelle 7: Gesamter Energiebedarf pro Jahr für die siebzehn berücksichtigten thermischen Zonen – Komfortband B: 21,8 °C bis 24,5 °C	46
Tabelle 8: Relevanz der Ergebnisse für Zielgruppen	59
Tabelle 9: Beschreibung des Dorn-Datensatzes	75
Tabelle 10: Beschreibung der generierten Daten im Rahmen des PersonAI-Projektes	76
Tabelle 11: Beschreibung der Metadaten	76

Abbildungsverzeichnis

Abbildung 1: Einladung zum Workshop am 25. April 2024 © DiLT Analytics	16
Abbildung 2: Abbildung der Vorgehensweise der Datenerhebung mit verwendeten Geräten, Fragebögen und Surveys © DiLT Analytics.....	18
Abbildung 3: Informationsveranstaltung für Teilnehmer:innen © DiLT Analytics	19
Abbildung 4: Eingesetzte Geräte - iPhone, Oura Ring und Apple Watch mit Cozie-App © TU Wien	20
Abbildung 5: Ein Ausschnitt aus den RHRN-Surveys, die siebenmal täglich per Cozie-App auf der Apple Watch präsentiert wurden © TU Wien.....	21
Abbildung 6: Living Lab ENERGETIKUM © Forschung Burgenland	27
Abbildung 7: Living Lab LOWERGETIKUM © Forschung Burgenland.....	28
Abbildung 8: Parameter des Zweipunktreglers © Forschung Burgenland	30
Abbildung 9: thermische Nebenbedingungen der prädiktiven Regelung © Forschung Burgenland	31
Abbildung 10: Thermische Präferenz der Teilnehmer:innen © TU Wien.....	35
Abbildung 11: Verteilung der Sensor-Merkmale über die Komfortklassen © TU Wien	36
Abbildung 12: Rückmeldungen Zufriedenheit - Warm Start © TU Wien.....	38
Abbildung 13: Rückmeldungen Zufriedenheit - Cold Start © TU Wien	39
Abbildung 14: Temperaturverläufe 2P-Regler (oben: Komfortband A; unten: Komfortband B) © Forschung Burgenland.....	40
Abbildung 15: Temperaturverläufe dezentraler DMPC mit stündlicher Re-Optimierung (oben: Komfortband A; unten: Komfortband B) © Forschung Burgenland	41
Abbildung 16: Temperaturverläufe 2P-Regler (oben: Komfortband A; unten: Komfortband B) © Forschung Burgenland.....	44
Abbildung 17: Temperaturverläufe dezentraler DMPC mit stündlicher Re-Optimierung (oben: Komfortband A; unten: Komfortband B) © Forschung Burgenland	45
Abbildung 18: Korrelationsanalyse - PersonAI © TU Wien.....	49
Abbildung 19: Klassenverteilung - Dorn vs. PersonAI © TU Wien	50
Abbildung 20: Konfusionsmatrix - Dorn Datensatz © TU Wien.....	51
Abbildung 21: Konfusionsmatrix - Einzelner Teilnehmer aus dem Dorn Datensatz © TU Wien	52
Abbildung 22: Vergleich Vorhersageleistungen - Dorn Datensatz © TU Wien.....	53
Abbildung 23: Vergleich Vorhersageleistungen - PersonAI Datensatz © TU Wien	53

Literaturverzeichnis

- Arakawa Martins, L., Soebarto, V., & Williamson, T. (2022). A systematic review of personal thermal comfort models. *Building and Environment*, 207, Article 108502. doi.org/10.1016/j.buildenv.2021.108502
- ASHRAE. (2020). Thermal environmental conditions for human occupancy (ASHRAE Standard 55-2020).
- ASHRAE. (2022). Ventilation for acceptable indoor air quality (ANSI/ASHRAE Standard 62.1-2022).
- Awada, M., Becerik-Gerber, B., Hoque, S., O'Neill, Z., Pedrielli, G., Wen, J., & Wu, T. (2021). Ten questions concerning occupant health in buildings during normal operations and extreme events including the COVID-19 pandemic. *Building and Environment*, 188, 107480. doi.org/10.1016/j.buildenv.2020.107480
- Bernabeu, J. (2017, 3. Februar). There is an unconscious gender bias in the Google algorithm. *Métode*. metode.org/issues/entrevista-revistas/londa-schiebinger.html
- Boyd, D. (2014, 28. März). Is the Oculus Rift sexist? *Quartz*. qz.com/192874/is-the-oculus-rift-designed-to-be-sexist
- Brasche, S., & Bischof, W. (2005). Daily time spent indoors in German homes—Baseline data for the assessment of indoor exposure of German occupants. *International Journal of Hygiene and Environmental Health*, 208(4), 247–253. doi.org/10.1016/j.ijheh.2005.03.003
- Cawley, G. C., & Talbot, N. L. C. (2010). On over-fitting in model selection and subsequent selection bias in performance evaluation. *Journal of Machine Learning Research*, 11, 2079–2107.
- Crook, B., & Burton, N. (2010). Indoor moulds, sick building syndrome and building related illness. *Fungal Biology Reviews*, 24(3–4), 47–57. doi.org/10.1016/j.fbr.2010.05.001
- Dentel, A., & Dietrich, U. (2006). *Thermische Behaglichkeit – Komfort in Gebäuden*. HafenCity Universität Hamburg.
- Derogatis, L. R. (1975). *The Brief Symptom Inventory (BSI)*. Clinical Psychometric Research.
- Devine-Wright, H., & Devine-Wright, P. (2005). Representing the demand side: 'Deficit' beliefs about domestic electricity users. In *Proceedings of the ECEEE Summer Study*.
- Diener, E., Emmons, R. A., Larsen, R. J., & Griffin, S. (1985). The satisfaction with life scale. *Journal of Personality Assessment*, 49, 71–75.
- Drgoňa, J., Arroyo, J., Figueroa, I., Blum, D., Arendt, K., Kim, D., Ollé, E., Oravec, J., Wetter, M., Vrabie, D., & Helsén, L. (2020). All you need to know about model predictive control for buildings. *Annual Reviews in Control*, 50, 190–232.
- EFrag. (2023). *European Sustainability Reporting Standards: ESRS S1 Own Workforce; ESRS S4 Consumers and End-Users*. European Financial Reporting Advisory Group. efrag.org/en/projects/esrs-set-1

European Commission. (2020, 17. Februar). *In focus: Energy efficiency in buildings*. commission.europa.eu/news/focus-energy-efficiency-buildings-2020-02-17_en

European Committee for Standardization. (2019). Energy performance of buildings—Ventilation for buildings—Part 1: Indoor environmental input parameters for design and assessment of energy performance of buildings addressing indoor air quality, thermal environment, lighting and acoustics—Module M1-6 (EN 16798-1:2019).

European Commission. (o. J.). *EU buildings factsheets*. ec.europa.eu/energy/eu-buildings-factsheets_en

Europäisches Parlament & Rat der Europäischen Union. (2024). *Richtlinie (EU) 2024/1275 über die Gesamtenergieeffizienz von Gebäuden (Neufassung)*. Amtsblatt der Europäischen Union. eur-lex.europa.eu/eli/dir/2024/1275/oj

Eveleth, R. (2014, 15. Dezember). How self-tracking apps exclude women. *The Atlantic*. theatlantic.com/technology/archive/2014/12/how-self-tracking-apps-exclude-women/383673/

FFG. (2026a). *scaleFLEX: Skalierbare Methode zur Optimierung der Energieflexibilität von Quartieren* [Projektbeschreibung]. FFG Projektdatenbank. projekte.ffg.at/projekt/4425006

FFG. (2026b). *Hub4FIECs: Scientific Hub for Flexible Energy Communities* [Projektbeschreibung]. FFG Projektdatenbank. projekte.ffg.at/projekt/4597880

Halhoul Merabet, G., Essaaidi, M., Ben Haddou, M., Qolomany, B., Qadir, J., Anan, M., Al-Fuqaha, A., Abid, M. R., & Benhaddou, D. (2021). Intelligent building control systems for thermal comfort and energy-efficiency: A systematic review of artificial intelligence-assisted techniques. *Renewable and Sustainable Energy Reviews*, 144, 110969. doi.org/10.1016/j.rser.2021.110969

Hampl, N., Sposato, R., Marterbauer, G., Nowshad, A., Strebl, M., Salmhofer, A., & Grohs, L. (2022). *Erneuerbare Energien in Österreich 2022*.

Han, J., Bae, J., Jang, J., Baek, J., & Leigh, S.-B. (2019). The derivation of cooling set-point temperature in an HVAC system, considering mean radiant temperature. *Sustainability*, 11(19), 5417. doi.org/10.3390/su11195417

Hargreaves, T., Nye, M., & Burgess, J. (2010). Making energy visible: A qualitative field study of how householders interact with feedback from smart energy monitors. *Energy Policy*, 38(10), 6111–6119. doi.org/10.1016/j.enpol.2010.05.068

Hörner, M., & Knissel, J. (2023). *ENOB:dataNWG – Forschungsdatenbank Nichtwohngebäude: Ergebnisbericht*. Institut Wohnen und Umwelt. [Datanwg.de](https://datanwg.de)

ISO. (2005). Ergonomics of the thermal environment—Analytical determination and interpretation of thermal comfort using calculation of the PMV and PPD indices and local thermal comfort criteria (ISO 7730:2005).

Jung, W., & Jazizadeh, F. (2019). Human-in-the-loop HVAC operations: A quantitative review on occupancy, comfort, and energy-efficiency dimensions. *Applied Energy*, 239, 26–43. doi.org/10.1016/j.apenergy.2019.01.070

- Kim, J., Schiavon, S., & Brager, G. (2018). Personal comfort models—a new paradigm in thermal comfort for occupant-centric environmental control. *Building and Environment*, 132, 114–124. doi.org/10.1016/j.buildenv.2018.01.023
- Klanatsky, P., Veynandt, F., & Heschl, C. (2025a). A reliable mixed-integer linear programming formulation for data-driven model predictive control in buildings. *MethodsX*, 15, 103470. doi.org/10.1016/j.mex.2025.103470
- Klanatsky, P., Veynandt, F., & Heschl, C. (2025b). Data-driven model predictive control for buildings with glass façade and thermally activated building structure. *Energy and Buildings*, 336, 115205. doi.org/10.1016/j.enbuild.2024.115205
- Klanatsky, P., Veynandt, F., & Heschl, C. (2025c). An integrated development framework for data-driven model predictive control of thermal zones in buildings. *MethodsX*, 15, 103698. doi.org/10.1016/j.mex.2025.103698
- Klanatsky, P., Plank, H., & Heschl, C. (2020). *Energy demand reduction due to an intelligent shading control strategy*. Fachhochschule Burgenland / Forschung Burgenland, Pinkafeld. diglib.tugraz.at/download.php?id=6059bd1503bfd&location=datacite
- Klepeis, N. E., Nelson, W. C., Ott, W. R., Robinson, J. P., Tsang, A. M., Switzer, P., Behar, J. V., Hern, S. C., & Engelmann, W. H. (2001). The national human activity pattern survey (NHAPS): A resource for assessing exposure to environmental pollutants. *Journal of Exposure Analysis and Environmental Epidemiology*, 11(3), 231–252. doi.org/10.1038/sj.jea.7500165
- Mehling, W. E., Acree, M., Stewart, A., Silas, J., & Jones, A. (2018). The Multidimensional Assessment of Interoceptive Awareness, Version 2 (MAIA-2). *PLOS ONE*, 13(12), e0208034. doi.org/10.1371/journal.pone.0208034
- Melikov, A. K. (2015). Advanced air distribution: Improving health and comfort while reducing energy use. *Indoor Air*, 26(1), 112–124. doi.org/10.1111/ina.12206
- Nazarian, N., Liu, S., Kohler, M., Lee, J., Miller, C., Chow, W., Alhadad, S. B., Martilli, A., Quintana, M., Sunden, L., & Norford, L. (2021). Project Coolbit: Can your watch predict heat stress and thermal comfort sensation? *Environmental Research Letters*, 16(2), 025002. doi.org/10.1088/1748-9326/abd130
- Ngarambe, J., Yun, G. Y., & Santamouris, M. (2020). The use of artificial intelligence (AI) methods in the prediction of thermal comfort in buildings: Energy implications of AI-based thermal comfort controls. *Energy and Buildings*, 211, 109776. doi.org/10.1016/j.enbuild.2020.109776
- Niethammer, C. (2020, 2. März). AI bias could put women's lives at risk—a challenge for regulators. *Forbes*. forbes.com/sites/carmenniethammer/2020/03/02/ai-bias-could-put-womens-lives-at-risk-a-challenge-for-regulators/
- O'Brien, W., Wagner, A., Schweiker, M., Mahdavi, A., Day, J., Kjærgaard, M. B., Carlucci, S., Dong, B., Tahmasebi, F., Yan, D., Hong, T., Gunay, H. B., Nagy, Z., Miller, C., & Berger, C. (2020). Introducing IEA EBC Annex 79: Key challenges and opportunities in the field of occupant-centric building design and operation. *Building and Environment*, 178, 106897. doi.org/10.1016/j.buildenv.2020.106897

- Park, H., & Park, D. (2022). Prediction of individual thermal comfort based on ensemble transfer learning method using wearable and environmental sensors. *Building and Environment*, 207, 108485. doi.org/10.1016/j.buildenv.2021.108485
- Perrault, R., Shoham, Y., Brynjolfsson, E., Clark, J., Etchemendy, J., Grosz, B., Lyons, T., Manyika, J., Mishra, S., & Niebles, J. C. (2019). *The AI index 2019 annual report*. Stanford University, Human-Centered AI Institute.
- Quintana, M., Schiavon, S., Tartarini, F., Kim, J., & Miller, C. (2023). Cohort comfort models—Using occupants' similarity to predict personal thermal preference with less data. *Building and Environment*, 227, 109347. doi.org/10.1016/j.buildenv.2022.109685
- Rohrhofer, M. (2022, 15. Oktober). Rüsten für die Kälte: Auf den Ämtern wird es frisch. *Der Standard*. derstandard.at/story/2000139994042/ruesten-fuer-die-kaelte-auf-den-aemtern-wird-es-frisch
- Schweiger, G., Eckerstorfer, L. V., Hafner, I., Fleischhacker, A., Radl, J., Glock, B., Wastian, M., Rößler, M., Lettner, G., Popper, N., & Corcoran, K. (2020). Active consumer participation in smart energy systems. *Energy and Buildings*, 227, 110359. doi.org/10.1016/j.enbuild.2020.110359
- Seguel, J. M., Merrill, R., & Seguel, D. (2016). Indoor air quality. *American Journal of Lifestyle Medicine*, 11(4), 284–295. doi.org/10.1177/1559827616634497
- Seremeti, L., & Kougias, I. (2021). The legalhood of artificial intelligence: AI applications as energy services. *Journal of Artificial Intelligence and Systems*, 3, 83–92.
- Shi, Z., & O'Brien, W. (2019). Development and implementation of automated fault detection and diagnostics for building systems: A review. *Automation in Construction*, 104, 215–229. doi.org/10.1016/j.autcon.2019.04.002
- Simonite, T. (2018, 17. August). AI is the future—but where are the women? *Wired*. wired.com/story/artificial-intelligence-researchers-gender-imbalance/
- Soto, C. J., & John, O. P. (2017). Short and extra-short forms of the Big Five Inventory–2: The BFI-2-S and the BFI-2-XS. *Journal of Research in Personality*, 68, 69–81. doi.org/10.1016/j.jrp.2017.02.004
- Stopps, H., Huchuk, B., Touchie, M., & O'Brien, W. (2021). Is anyone home? A critical review of occupant-centric smart HVAC controls implementations in residential buildings. *Building and Environment*, 187, 107401. doi.org/10.1016/j.buildenv.2020.107401
- Tartarini, F., Frei, M., Schiavon, S., Chua, Y. X., & Miller, C. (2023). Cozie Apple: An iOS mobile and smartwatch application for environmental quality satisfaction and physiological data collection. *Journal of Physics: Conference Series*, 2600, 142003. doi.org/10.1088/1742-6596/2600/14/142003
- Tartarini, F., Schiavon, S., Quintana, M., & Miller, C. (2022). Personal comfort models based on a 6-month experiment using environmental parameters and data from wearables. *Indoor Air*, 32(6), e13160. doi.org/10.1111/ina.13160

Vasquez-Canteli, J., & Nagy, Z. (2019). Reinforcement learning for demand response: A review of algorithms and modeling techniques. *Applied Energy*, 235, 1072–1089. doi.org/10.1016/j.apenergy.2018.11.002

vienna.at. (2022, 6. Oktober). Vorerst keine Temperatursenkung in Wiener Amtsgebäuden. *Vienna.at*. vienna.at/vorerst-keine-temperatursenkung-in-wiener-amtsgebaeuden/7676341

Walentynowicz, M., Erbaş, Y., Joran, J., Leonie, V. V., & Luminet, O. (2023). Interoception in daily life: Development and validation of momentary body awareness scale. In *SAA 2023* (S. 127).

Wargocki, P., Porras-Salazar, J., & Contreras-Espinoza, S. (2019). The relationship between classroom temperature and children's performance in school. *Building and Environment*, 157, 197–204. doi.org/10.1016/j.buildenv.2019.04.046

World Economic Forum. (2020). *Global gender gap report 2020*.

Xie, J., Li, H., Li, C., Zhang, J., & Luo, M. (2020). Review on occupant-centric thermal comfort sensing, predicting, and controlling. *Energy and Buildings*, 226, 110392. doi.org/10.1016/j.enbuild.2020.110392

Yates, L. A., Aandahl, Z., Richards, S. A., & Brook, B. W. (2023). Cross validation for model selection: A review with examples from ecology. *Ecological Monographs*, 93(1), e1557. doi.org/10.1002/ecm.1557

Zeeshan, A., Khan, S., & Sohail, N. (2022). Investigating the gender differences in indoor thermal comfort perception for summer and winter seasons and comparison of comfort temperature prediction methods. *Journal of Thermal Biology*, 110, 103366. doi.org/10.1016/j.jtherbio.2022.103366

Abkürzungen

2P-Regler	Zweipunktregler
ASHRAE	American Society of Heating, Refrigerating and Air-Conditioning Engineers
BFI-2-S	Big Five Inventory–2–Short
BFI-2-XS	Big Five Inventory–2–Extra Short
BSI	Brief Symptom Inventory
CCM	Cohort Comfort Models
DMPC	Data-Driven Model Predictive Control
DSGVO	Datenschutz-Grundverordnung
EMA	Ecological Momentary Assessment
EPBD	Energy Performance of Buildings Directive
ESG	Environmental, Social and Governance
ESRS	European Sustainability Reporting Standards
FDD	Fault Detection and Diagnostics
HVAC	Heating, Ventilation and Air Conditioning
IAQ	Indoor Air Quality
ICM	Indoor Climate Management
IEQ	Indoor Environmental Quality
IQR	Interquartilsbereich
LOOCV	Leave-One-Out Cross-Validation
MAIA-2	Multidimensional Assessment of Interoceptive Awareness, Version 2
MILP	Mixed-Integer Linear Programming
PCA	Principal Component Analysis
PCM	Personal Comfort Models
PMV	Predicted Mean Vote
PV	Photovoltaik
RHRN	Right-Here-Right-Now (Surveys)
SAM	Serviceable Addressable Market

SMOTE-NC	Synthetic Minority Over-sampling Technique for Nominal and Continuous
SWLS	Satisfaction with Life Scale
TABS	Thermisch aktivierte Bauteilsysteme
TAM	Total Addressable Market
TGA	Technische Gebäudeausrüstung

Data Management Plan (DMP)

1: Datenerstellung und Dokumentation

Im PersonAI-Projekt wurden Sekundärdaten aus einem anderen Vorhaben erneut analysiert (Tartatini et al., 2022). Der Datensatz trägt den Namen DORN und ist öffentlich über das GitHub-Repository zugänglich. In Tabelle 9 ist eine zusammenfassende Beschreibung des Datensatzes angeführt.

Tabelle 9: Beschreibung des Dorn-Datensatzes

Beschreibung	Typ	Art	Quelle	Zugang	Link
DORN-Datensatz	Numerisch	Subjektive Self-Report-Daten; physiologische Daten; objektive Sensordaten; abgeleitete Features und Modelle	Sekundärdaten aus der Studie Tartatini et al. 2022 (GitHub)	Öffentlich	https://github.com/FedericoTartatini/dorn-longitudinal-tc-study

Zugleich bestand ein Großteil des Projekts aus der Generierung von eigenen Daten, die wir mit den Ergebnissen des DORN-Datensatzes vergleichen können. Dieser Datensatz besteht aus subjektiven, physiologischen und objektiven Daten, auf denen die Komfortmodelle aufgebaut sind. Für die Beschreibung der Daten sowie der Metadaten siehe Tabelle 10 und Tabelle 11 .

Tabelle 10: Beschreibung der generierten Daten im Rahmen des PersonAI-Projektes

ID	Beschreibung	Typ	Art	Verantwortlich	Zugang
PersonAI-Datensatz	Numerisch	Subjektive Self-Report- und physiologische Daten, objektive Sensordaten; abgeleitete Features und Modelle	Primärdaten	TU Wien	Eingeschränkt, nach Publikation offen.

Tabelle 11: Beschreibung der Metadaten

Attribut	Beschreibung
ID	PersonAI-Datensatz
Titel	Personai.csv
Zusammenfassung	Im selbstgenerierten Datensatz sind Daten zur Generierung von Komfortmodellen enthalten. Diese Daten umfassen Umgebungsdaten (Temperatur und Luftfeuchtigkeit), subjektive (psychologische Fragebögen sowie RHRN-Surveys) und physiologische Daten (Herzfrequenz).
Kurzbezeichnung	Daten zur Berechnung der Komfortmodelle
Einheit	Je nach Datenart: °C für Temperatur, % für Luftfeuchte, Skalenpunkte für Fragebögen und RHRN-Surveys, Herzschläge pro Minute für Herzfrequenz.
Zeitintervall	Minuten
Zeitraum und Referenzjahr	4 Wochen im Frühling 2025 (April-Mai)
Institution	Integrale Gebäudetechnik, TU Wien (https://www.tuwien.at/cee/hib)
Kontakt	Univ.Prof. Mag.phil. Dr.techn. Gerald Schweiger (gerald.schweiger@tuwien.ac.at)

Mitwirkende und Rolle	Katja Ceplak, BSc MSc (katja.ceplak@tuwien.ac.at) – Project Manager Projekttass. Dipl.-Ing. Dr.techn. Thomas Hirsch (thomas.hirsch@tuwien.ac.at) – Arbeitspaket Lead
Methodik	Die Daten wurden im Rahmen der empirischen Studie generiert. Die Teilnehmer:innen haben für vier Wochen täglich mehrere RHRN-Surveys sowie einen Onboarding Fragekatalog ausgefüllt (subjektive, selbstberichtete Daten). Zugleich trugen sie für vier Wochen Wearables, die ihre Herzfrequenz gemessen haben (physiologische Daten) und haben in ihrer Umgebung Luftsensoren aufgestellt, um die Temperatur, Luftfeuchte und CO2-Konzentration zu messen (objektive Daten).
Datenvervollständigung	Interpolation.
Quelldaten	Daten aus der empirischen Studie
Erstellungsdatum	2025-08-01
Datentyp	Subjektive Self-Report- und physiologische Daten, objektive Sensordaten; abgeleitete Features und Modelle
Versionsstand	Endgültige Version

2. Ethische, rechtliche und Sicherheitsaspekte

Die Daten wurden bereits bei der Erhebung pseudonymisiert erfasst und gespeichert. Die Teilnehmer:innen erhielten in der Informationsveranstaltung einen Teilnehmenden-Code, der in zufälliger Reihenfolge auf den Sitzplätzen neben den bereitgestellten Geräten ausgelegt war. Nur die Teilnehmer:innen selbst wissen, welcher Code ihnen zugeordnet ist. Der Code wurde für alle Eingaben verwendet: für die Onboarding-Befragung, die RHRN-Surveys sowie die Nutzung der Oura-Plattform. Bei einem Löschwunsch können Teilnehmer:innen mit ihrem Code auf uns zukommen. Der zugehörige Datensatz wird dann gelöscht. Ohne Code ist eine Zuordnung von Datensätzen zu Personen nicht möglich.

Für die Dauer der Datenerhebung wurde eine separate, passwortgeschützte Kontaktliste auf einem Universitätsserver geführt, um Informationen an die Teilnehmer:innen zu übermitteln (z. B. Studienende, Rückgabetermine für Geräte, Hinweise zu Anwendungen oder Geräten). Diese Liste wurde nach Abschluss der Datenerhebung unwiderruflich gelöscht. Da Herzfrequenzdaten nach DSGVO zu den besonderen Kategorien personenbezogener Daten zählen, werden sie mit besonderer Sorgfalt behandelt. Einwilligungs- und Datenschutzerklärungen werden für zehn Jahre aufbewahrt. Es bestehen keine zu berücksichtigenden vertraglichen Verpflichtungen.

3. Datenspeicherung und -erhalt

Die Daten werden auf projektinternen, passwortgeschützten Servern und Repositorien gespeichert. Backups erfolgen automatisiert in regelmäßigen Abständen. Die Verantwortung für die Daten liegt beim Konsortialführer, der TU Wien. Zur Sicherung guter wissenschaftlicher Praxis werden die Forschungsdaten auf gesicherten Datenträgern pseudonymisiert für zehn Jahre ab Veröffentlichung aufbewahrt (rechtliche Verpflichtung gemäß Universitätssatzung bzw. berechtigtes Interesse).

4. Wiederverwendbarkeit der Daten

Derzeit sind die Daten ausschließlich projektintern zugänglich. Nach Abschluss aller geplanten Publikationen werden die empirischen Daten in anonymisierter Form über Zenodo der Forschungsgemeinschaft zur Verfügung gestellt. Der im Projekt entwickelte und erweiterte Code wird über GitHub veröffentlicht; beide Repositorien werden im Zuge der Publikation auf öffentlichen Zugang umgestellt. Die Veröffentlichung erfolgt voraussichtlich bis Ende 2026.

Die Daten werden unter einer offenen Lizenz bereitgestellt, soweit datenschutzrechtlich zulässig. Nicht veröffentlicht werden Rohdaten sowie Datenkombinationen, die trotz Pseudonymisierung eine Re-Identifikation ermöglichen könnten. Der Opt-Out für diese Teile erfolgt aus Datenschutzgründen (Art. 9 DSGVO).

Kontakt:

Projektleitung: Univ.Prof. Mag.phil. Dr.techn. Gerald Schweiger, MA MA PhD - TU Wien

Projektpartner:innen: DiLT Analytics GmbH, Forschung Burgenland GmbH, Universität Graz

