

Energieforschungsprogramm

Publizierbarer Endbericht

Programmsteuerung:

Klima- und Energiefonds

Programmabwicklung:

Österreichische Forschungsförderungsgesellschaft mbH (FFG)

Endbericht

erstellt am

22/03/2019

Projekttitlel:

Intelligent energy-efficient home

Projektnummer: 853663

Energieforschungsprogramm - 02. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Ausschreibung	02. Ausschreibung Energieforschungsprogramm
Projektstart	01/01/2016
Projektende	31/12/2018
Gesamtprojektdauer (in Monaten)	36 Monate
ProjektnehmerIn (Institution)	Technische Universität Wien Institut für Mechanik und Mechatronik Abteilung für Regelungstechnik und Prozessautomatisierung
AnsprechpartnerIn	A.o.Univ. Prof. DI Dr. Martin Kozek
Postadresse	Getreidemarkt 9 / 325-6, 1060 Wien
Telefon	(+43-1) 58801/325-512
Fax	
E-mail	martin.kozek@tuwien.ac.at
Website	https://www.tuwien.ac.at/

IntelliEE-Home

Intelligent energy-efficient home

AutorInnen:



A.o.Univ. Prof. DI Dr. Martin Kozek

DI Dr.techn. Michaela Killian

DI Michael Zauner



DI Andreas Leitner

DI Robert Goldgruber

1 Inhaltsverzeichnis

1	Inhaltsverzeichnis	4
2	Einleitung	5
3	Inhaltliche Darstellung	6
3.1	Prozessmodellbildung	6
3.1.1	Gebäudemodellierung	6
3.1.2	NutzerInnen-Verhalten modellieren	11
3.1.3	Adaptive Modellierung	12
3.2	Adaptive-Prädiktive Regelung	13
3.3	Adaptive Datenverknüpfung	16
4	Ergebnisse und Schlussfolgerungen	18
5	Ausblick und Empfehlungen	24
6	Literaturverzeichnis	25
7	Anhang	26
8	Kontaktdaten	26

2 Einleitung

Der Energieverbrauch im Gebäudesektor hat mit rund 40% einen ganz wesentlichen Anteil am nationalen und internationalen Energiekonsum. Aus verschiedenen Quellen geht hervor, dass mit intelligenten Automatisierungssystemen der Energieeinsatz in Wohnhäusern signifikant reduziert werden kann [1].

Es ist ohne aufwendige bauliche Maßnahmen möglich den Energieverbrauch und den CO₂-Ausstoß für Gebäudeheizung und -kühlung sowohl in Neubauten als auch in Bestandsgebäuden mit intelligenten Automatisierungssystemen zu reduzieren (bis zu 40%). Besonders geeignet hierfür ist die modellprädiktive Regelung, welche zukünftige Störgrößen wie Wetter, Strahlung, und NutzerInnenverhalten explizit in ihrer Optimierung berücksichtigt. Im gegenständlichen Projekt soll eine intelligente modellprädiktive Regelung für ein Heim-Automatisierungssystem entworfen werden. Um mit geringstem Aufwand eine bestmögliche Anpassung an die spezielle Anwendung zu erhalten, wird neben dem prädiktiven Regelungskonzept auch ein selbstlernendes adaptives Modell des Gebäudes und des NutzerInnenverhaltens angepasst. Das selbstlernende Modell ist in der Lage durch Adaption an das NutzerInnenverhalten Modellfehler zu korrigieren und sich selbst im laufenden Betrieb neu zu parametrieren. Neben dem adaptiv-prädiktiven Regler liegt der Schwerpunkt der wissenschaftlichen Problemstellung auf einem geeigneten Datenverarbeitungsalgorithmus.

Durch die adaptiv-prädiktive Regelung steigt der thermische Komfort für NutzerInnen, während nachhaltig der Energieverbrauch reduziert wird. Außerdem wird eine flexible Nutzung erneuerbarer Energiequellen möglich, im einfachsten Fall durch eine integrierte smarte Storen-Regelung. Durch die Ansteuerung mit mobilen Endgeräten ist dieses Konzept leicht bedienbar und mittels intuitiven User-Interface für alle Kunden nutzerfreundlich. Überdies wird die Funktionalität für die aktive Teilnahmen an Smart Grids geschaffen.

Durch ein selbstlernendes System kombiniert mit prädiktiver Regelung im Eigenheimbereich definiert der Industriepartner evon automation GmbH ein Alleinstellungsmerkmal am Markt. Durch kostengünstige Implementierung wird somit eine große Anzahl an potentiellen Kunden angesprochen, sowohl im Feld der Neubauten als auch im Bereich des Retrofitting von Bestandsgebäuden. Durch diesen Multiplikatoreffekt ergibt sich ein sehr hohes Potenzial für CO₂-Einsparungen im Wohnsektor.

Der Bericht ist wie folgt aufgebaut: Kapitel 3 gibt die inhaltlichen Methoden und Algorithmen wieder. Im Besonderen wird auf die Modellbildung und die Datenverarbeitungsalgorithmen für die Extraktion des NutzerInnenverhaltens eingegangen. In Kap. 4 werden die Ergebnisse des Projektes illustrativ dargestellt. Der Fokus liegt hierbei bei den Ergebnissen aus der Implementierung des entwickelten Reglers in ein reales Demogebäude. Im 5.Kapitel wird ein breiter Ausblick über zukünftige Entwicklungen auf Basis der erarbeiteten Methoden erläutert. Kapitel 6 rundet den Endbericht schließlich mit einem umfassenden Literaturverzeichnis ab. Hierbei sei zu erwähnen, dass das Projekt auch aus wissenschaftlicher Sicht sehr erfolgreich war und eine Vielzahl von Publikationen hervorgebracht hat.

3 Inhaltliche Darstellung

3.1 Prozessmodellbildung

Das Ziel bei der Prozessmodellbildung ist es, ein Modell für den Gesamtprozess zu erstellen, welche für den Reglerentwurf relevant und nutzbar ist. Durch diese Anforderung entstehen natürliche Einschränkungen in der Modellierung und ebenso in der Modellgenauigkeit, da es für modellprädiktive Regelung im Gebäude ausreichend ist, ein zugrundeliegendes Modell der mittleren Raumtemperatur zu kennen. Nichtsdestotrotz ist neben dem Gebäudemodell selbst auch die Modellierung des NutzerInnen-Verhaltens von hoher Priorität.

3.1.1 Gebäudemodellierung

In diesem Kapitel liegt das Hauptaugenmerk am Gebäudemodell selbst. Diese Gebäudemodelle beschreiben klassische Gebäudedynamiken und wurden aus Messdaten erstellt. Für das Gebäudemodell selbst werden 3 große Modellierungsansätze unterschieden:

1) Hammerstein-Modell

Das Hammerstein-Modell (siehe Abb.1) ist eine spezielle Modellform für nichtlineare dynamische Systeme. Charakteristisch ist die Struktur, bestehend aus der Reihenschaltung einer statischen Nichtlinearität vor einem linearen zeitinvarianten dynamischen System. Das Hammerstein-Modell ist sowohl für Eingrößen- also auch für Mehrgrößensysteme definiert. Bei Gebäuden wird klassischerweise mit der Umgebungstemperatur (u) eine Vorsteuerung mit einer nichtlinearen Kennlinie (Heizkurve) durchgeführt, damit die Vorlauf-temperatur (\tilde{u}) eine entsprechende Raumtemperatur (y) sicherstellen kann.




Abbildung 1: Blockschaltbild eines Hammerstein-Modells, das aus der Reihenschaltung einer statischen Nichtlinearität vor einem linearen System besteht.

2) Wiener-Modell

Wiener-Modelle (siehe Abb. 2) sind ebenfalls spezielle Modellform für nichtlineare dynamische Systeme. Charakteristisch ist die Struktur, bestehend aus der Reihenschaltung einem linearen zeitinvarianten dynamischen System vor einer statischen Nichtlinearität. Das Wiener-Modell ist genauso wie das Hammerstein-Modell sowohl für Eingrößen- als auch für Mehrgrößensysteme definiert.




Abbildung 2: Blockschaltbild eines Wiener-Modells, das aus der Reihenschaltung einer statischen Nichtlinearität hinter einem linearen System besteht.

3) Lokal lineare Modellnetzwerke (LLMN)

Neben den bereits genannten dynamischen Modellierungsansätzen wurde die Methode zur Analyse eines linearen Modellnetzwerks aus experimenteller Systemidentifikation entwickelt. Im folgenden Bild (Abb. 3) sieht man die grobe Arbeitsweise vom sogenannten Lokal linear Modellnetzwerk Algorithmus (LoLiMoT), und dessen Teilung in lokal lineare Modelle:




Abbildung 3: Dieses Bild zeigt die Aufteilung des LoLiMoT Algorithmus.

Diese Grafik zeigt eine mögliche Partitionierung des Input-Raums (x_1, x_2) (Dateneingang/Regressors) mit dem Profil einer nicht-normalisierten Gewichtungsfunktion. Bei Gebäuden ist typischerweise x_1 die Außentemperatur und z.B. x_2 die aktuelle Heiz- bzw. Kühlleistung. Diese gewählte Partitionierung ist immer jene/r Parameter, welche/r die Nichtlinearität beschreibt. Genauer geht dieser Algorithmus, wie in folgendem Bild (Abb. 4) dargestellt, vor:




Abbildung 4: Dieses Bild zeigt die Aufteilung der Hyperquader, abhängig von der Reihenfolge.

In Abb. 4 sieht man 6 Iterationsschritte des LoLiMoT-Algorithmus. Über diese Methodik können zum Beispiel die Systemmatrizen aus dem nichtlinearen dynamischen Gebäudemodell gewonnen werden und direkt in die Reglerstruktur integriert werden. Außerdem kann man zum Beispiel jede Gebäudezone (Teilung in Stockwerke, nach Himmelsrichtung, oder nach Raumnutzung) als lokal lineares Modell darstellen um optimale Performance in den etwaigen Zonen zu gewährleisten.

Der LoLiMoT-Algorithmus besteht im Wesentlichen aus zwei großen ineinander verschachtelten Iterationsschleifen. In der äußeren Schleife wird in jeder Iteration der Hyperquader, der die Funktion in seinem Bereich am schlechtesten annähert, ausgewählt. Dieser wird dann in der inneren Schleife nacheinander entlang jeder Dimension des Eingangsraumes halbiert (siehe Abb. 4). Für jede dieser Möglichkeiten wird ein komplett neues Modell berechnet, um qualitativ zu entscheiden, welche Teilungsrichtung den größten Genauigkeitsgewinn ermöglicht.

In Abb. 5 links sieht man die sogenannten Membership Funktionen oder auch Zugehörigkeitsfunktionen, sie dienen beim Entwurf einer Fuzzy Regelung (siehe AP 3). Hierzu werden alle Eingangsgrößen in sogenannten „Fuzzy-Sets“ zusammengefasst. Fuzzy Sets geben für jeden Wert einer Eingangsgröße den dazugehörigen Erfüllungsgrad einer fuzzylogischen Aussage an („wenn“ – „dann“ Verknüpfungen). Genau diese stellen eine Zugehörigkeitsfunktion auf. In unserer Software werden die Gewichtungsfunktionen durch normalisierte Gaußkurven dargestellt. Durch die Normierung der Gewichtungsfunktionen kommt es an den Rändern des Messbereiches nicht zu einem Abfallen auf Null – stattdessen werden die Randwerte linear extrapoliert, siehe Abb. 5 rechts.




Abbildung 5: links: membership Funktionen von 3 lokal linearen Modellen; rechts: die dazugehörigen normalisierten Gauss-Gewichtungsfunktionen.

4) **Lineare Modelldatenbank**

Ein zusätzlicher Algorithmus kann aus den oben genannten Modelltypen, das „beste“ Modell für den jeweiligen Gebäudetyp (Größe, Lage, Bauart, Nutzung, etc.) automatisch extrahieren (zu diesem Algorithmus wurde bereits eine Erfindungsmeldung eingereicht). Dieser spezielle Algorithmus verwendet statistische Auswertungen und Größen um die Modellgüte zu bewerten. Die dem Algorithmus unterliegenden Initialmodelle werden für das Reglerdesign passend aus historisch ermittelten Modellen ausgewählt, um für den speziellen Gebäudetyp die höchste Performance zu erzielen. Dieser Algorithmus entscheidet anhand von verschiedenen statistischen Tests (t-Test und resultierenden p-Wert, R^2 -Wert, RMSE-Wert (jeweils über die Zeit)) und Gütefunktionalen on-line, ob ein Modell zu den gemessenen Daten passt oder ob man es verwerfen kann. Hierzu werden verschiedene Modelle in den Algorithmus gespeist (linear, nichtlinear, verschiedene Ordnung, verschiedene Zeitkonstanten, etc.).

Die ersten Resultate aus generischen Modellen sahen wie folgt aus:




Abbildung 6: Erste Simulationsergebnisse für die Auswahl der plug-and-play Software für die Modellauswahl des adaptiv-prädiktive Regelungsverfahrens.

In Abb. 6 sieht man ein Szenario über 96 h (4 Tage), welches die Grundidee des eben beschriebenen Selektionsalgorithmus darstellt. In Abb. 6/1 sieht man jenen Schwellenwert der entscheidet ob im Gebäude das Heiz- oder Kühlmodell aktiv ist. Der Schwellenwert wird durch die Außentemperatur charakterisiert. Aufgrund dieses Schwellwertes wechselt das „reale Gebäude“ in den gewünschten Modus (siehe Abb. 6/2: die durchgezogene schwarze Linie stellt das reale Gebäude ohne Messrauschen dar). In dieser Simulation hat der Algorithmus 3 verschiedene Modelle als Initialmodelle zur Auswahl. Ein Modell, welches dem realen Heizmodell sehr ähnlich ist (Abb. 6/2 Modell 1 strichlierte rote Linie), das gleiche gilt für den Kühlmodus (Abb. 6/2 Modell 2 strichlierte blaue Linie), und ein drittes Modell welches weder auf Heiz- noch Kühlmode des realen Gebäudes passt (Abb. 6/2 Modell 3 durchgezogene grüne Linie). Ziel des Algorithmus ist es, anhand eines t-Tests, der R^2 -Werte, der RMSE-Werte, und der aus der t-Statistik resultierenden p-Werte das zum jeweiligen Zeitpunkt beste Modell zu erkennen. Getestet werden diese Initialmodelle jedoch nicht auf die „reinen“ Daten des realen Gebäudes, sondern auf jene die mit Messrauschen versehen wurden (Abb. 6/2 durchgezogene magenta Linie). In Abb. 6 erkennt man, dass die schwarze Linie (Daten des „realen Gebäudes“) zum Zeitpunkt des Schnittpunktes zwischen Außentemperatur und Schwellenwert, vom Kühlmodell in das Heizmodell übergeht. In Abb. 6/3 sind die R^2 -Werte der drei Initialmodelle gegeben. Das Bestimmtheitsmaß R^2 ist ein statistisches Gütemaß. Es zeigt, wieviel Variation in den Daten durch ein vorliegendes Regressionsmodell erklärt werden kann. Der R^2 -Wert ist im Intervall $[0,1]$ definiert, wobei 0 bedeutet, dass das gewählte Modell keinen Zusammenhang mit den

Messdaten besitzt und der Wert 1 bedeutet, dass es sich um ein perfektes Modell handelt. Man erkennt in Abb. 6/3, dass zuerst der R^2 -Wert des Kühlmodells am höchsten ist, und somit dieses Modell als „wahr“ gilt, nach überqueren des Schwellwertes, variieren die R^2 -Werte und das Heizmodell wird als bestes Modell kalkuliert. Ähnliches Ergebnis zeigt ein weiteres statisches Maß in Abb. 6/4, der p-Wert der t-Statistik. Der p-Wert ist eine Wahrscheinlichkeit und nimmt daher Werte zwischen Null und Eins an. Der Wert wird durch die gezogene Stichprobe bestimmt. Er deutet an, wie wahrscheinlich es ist, ein solches Stichprobenergebnis oder ein extremeres zu erhalten, wenn die Nullhypothese des t-Tests nicht abgelehnt werden kann.

3.1.2 NutzerInnen-Verhalten modellieren

Ein weiterer wichtiger Punkt ist es neben der Gebäudemodellierung und der Auswahl des geeigneten Initialmodells für das Reglerdesign, die Gebäudenutzung bzw. unterliegende NutzerInnen-Verhalten darzustellen. Da im Allgemein Präsenzdaten über NutzerInnen schwierig zu bekommen sind, werden dafür die Messdaten der Lichtsteuerung verwendet. Diese Daten wurden ausgewertet und analysiert. Verschiedene NutzerInnen-Profile, abhängig von Gebäudenutzung können dann hinterlegt werden. Ebenfalls möglich ist eine automatische Extraktion neuer NutzerInnen-Profile mittels Cloud-Computing. In Abb. 7 sieht man zwei verschiedene Nutzungstypen. Abb. 7 links zeigt die Nutzung eines Bürogebäudes, während Abb. 7 rechts die Nutzung eines Eigenheims einer vollzeitarbeitstätigen Person zeigt:




Abbildung 7: Typische Nutzungsprofile von Büroflächen (links) und Eigenheimen (rechts). Anmerkung: Die Werte der Ordinatenachse sind wie folgt zu verstehen: 0 = 0 % anwesend, 1 = 100 % anwesend.

Eine weitere Unterscheidung in der Gebäudenutzung muss man bei der genderspezifischen Fragestellung treffen (ebenso bei nicht-erwerbstätigen Personen), diese Thematik wurde näher beleuchtet und analysiert und war Teil der ausgeschriebenen Diplomarbeit (siehe Publikationen [9]). In der Literaturrecherche zum Thema Gender und Diversity gab es einige zum Teil überraschende Ergebnisse. Während in der älteren Literatur die genderspezifischen Unterschiede bei der thermischen Wahrnehmung als insignifikant deklariert wurde, liefern neuere Publikationen Anzeichen von signifikanten Unterschieden. Weibliche Personen werden auf thermische Abweichungen von der persönlichen Idealtemperatur früher aufmerksam. Diese persönliche Idealtemperatur ist von Person zu

Person unterschiedlich, jedoch hat sich gezeigt, dass weibliche Personen im Mittel eine höhere Idealtemperatur bevorzugen. Außerdem hat sich gezeigt, dass weibliche Personen in gemeinsamen Haushalten das Heizungs-Thermostat seltener benutzen. Ebenso gibt es Anzeichen, dass ältere Personen Probleme mit modernen (und komplizierten) Heizungs-Thermostaten haben. Deshalb ist es für ein User-Interface unbedingt notwendig intuitiv und benutzerfreundlich zu sein. Evon Home bietet hierbei ein vorbildliches User-Interface an, welches aufgeräumt und intuitiv ist, siehe Abb. 8.

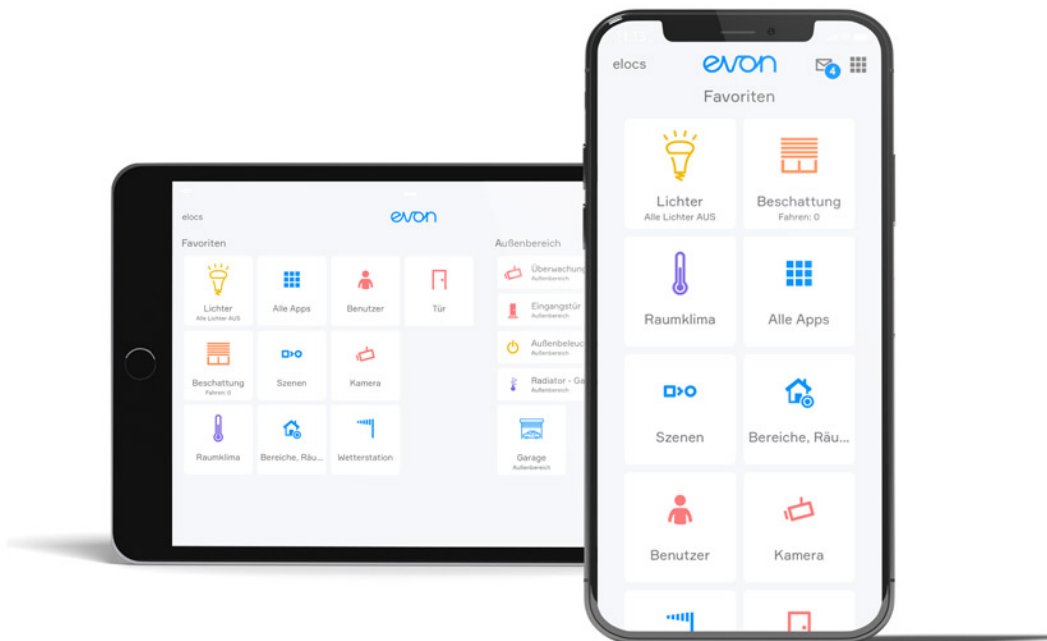


Abbildung 8: Evon User-Interface auf verschiedenen Endgeräten.

Es hat sich ebenfalls herausgestellt, dass viele Personen mit absoluten Temperaturangaben (22°C, 23°C, ...) nicht viel anfangen können, jedoch mit relativen Angaben (z.B. +1°C, +2°C, ...) ihre Idealtemperatur leichter erreichen können. Im speziellen muss ebenfalls auf ältere Personen eingegangen werden, da diese besonderen Ansprüche an thermischen Komfort haben.

3.1.3 Adaptive Modellierung

Der adaptive Modellierungs-Algorithmus ist in Abb. 9 dargestellt.

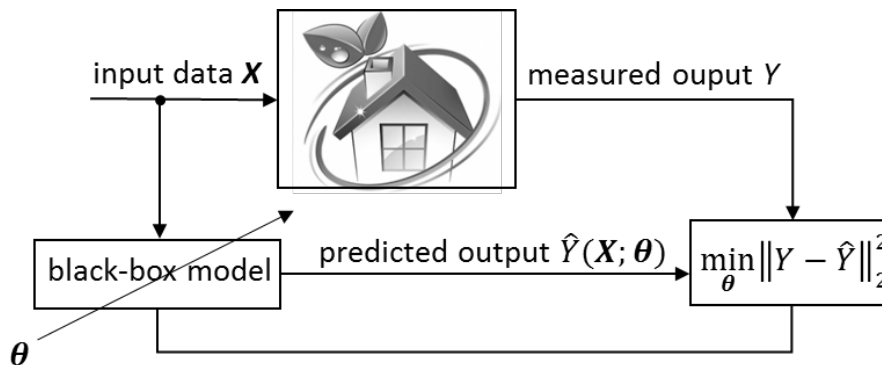


Abbildung 9: Adaptive Algorithmus für die Parameteradaption der Modellierung.

Die Abbildung zeigt den on-line Arbeitszyklus einer adaptiven Modellierung:

- 1) Im ersten Schritt werden die Parameter θ aus den bereits vorgestellten Modellen geschätzt. Zu beachten ist, dass die Eingangsdaten X sowohl in die Modelle wie auch in das reale Gebäude gespeist werden.
- 2) Im zweiten Schritt werden die Ausgänge der verschiedenen Modelle (simuliert/prädiziert \hat{Y}) mit jenen Ausgängen aus dem realen Gebäude (Messungen Y) verglichen und deren quadratische Abweichung bewertet.
- 3) Auswahl und laufende Adaption der Modelle, bis die Modellperformance einem vorgegebenen Gütefunktional reicht.

Auf diese Art und Weise kann einfach und ohne menschliche Intervention das jeweils optimale Modell für das Gebäude gewählt werden. Hierbei geht es nicht nur um Modelle für verschiedene Gebäudetypen (Passivhaus-Neubau, Altbau-Retrofit, ...), sondern auch um Modelle für verschiedene Jahreszeiten und Betriebsweisen. So sollte gegen Ende der Heizperiode zuerst das passende Wintermodell adaptiert werden solange bis das Modell für die Übergangszeit bessere Performance liefert. Der Wechsel vom Wintermodell auf das Modell für die Übergangszeit passiert dann automatisch ohne, dass die NutzerInnen davon etwas mitbekommen.

3.2 Adaptive-Prädiktive Regelung

Die Nichtlinearität des Modells wurde im Reglerentwurf berücksichtigt und ein passendes Regelungskonzept bzw. mehrere passende Konzepte wurden entworfen.

Die Reglerziele sind klar formuliert:

- User-Akzeptanz und die Bedürfnisse der individuellen Nutzer stehen klar im Vordergrund
- Performance steht über Energieoptimalität
- Energieoptimale Fahrweise wird automatisch gewählt, sobald der Nutzer nicht anwesend ist, oder dieses Ziel klar seinen Performancezielen bevorzugt

Außerdem sind die Rahmenbedingungen, sowie Stell-, Stör-, Zustands-, und Regelgrößen definiert und mit dem Partner evon GmbH (genannte Größen sind von Messdaten abhängig) abgeglichen:

- Stellgrößen:

- Vorlauftemperatur direkt (falls Messung und Durchgriff vorhanden)
- Adaption der Heiz- bzw. Kühlkurve um somit indirekten Durchgriff auf die Vorlauftemperaturen für die Heizung / Kühlung zu erzielen
- Storen (falls Nutzer nicht anwesend, oder dies ausdrücklich wünscht)
- Störgrößen:
 - Strahlung
 - Außentemperatur
 - Abhängig von Lage: Wind / Niederschlag
 - Beschattung (Bäume, angrenzende Wohnanlagen / Häuser)
- Zustandsgrößen:
 - Nutzer ist an-/abwesend
 - Speicherfüllstand und Mode: auffüllen / entladen / durchziehen
 - Zustand der Aggregate (Latenzzeiten)
 - Zustand im Grid und smarterer Haushaltsgeräte
- Regelgrößen:
 - Raumtemperatur in Gebäudezonen / Einzelräumen

Das zu optimierende Zielfunktional ist beschrieben und ebenso dessen technische und thermische Beschränkungen sind bekannt und im Optimierungsproblem formuliert (modellprädiktiver Regler). Ein weiterer relevanter Punkt ist die Einteilung in Regelzonen, dies kann durch folgende Punkte gekennzeichnet werden:

- Jeder Raum ist eine Zone
- Räume auf einer Himmelsrichtung sind eine Zone
- Gebäudeetagen sind eine Zone
- Abhängig von Versorgungsstrang: pro Zone muss eine unabhängige regelbare Versorgung gewährleistet sein
- Einteilung durch Nutzer: Nassräume, Wohnräume und Schlafräume etc. werden je in einer Zone zusammengefasst

Das Grundprinzip einer sogenannten Fuzzy Regelung baut auf diesen Zonen, und denen im vorherigen Kapitel erwähnten lokal linearen Modellnetzwerken auf. Jede Zone wird als lokal lineares Modell definiert, durch geeignete Gewichtungsfunktionen können die Regelziele der einzelnen Zonen fair gewichtet werden um das Optimierungsoptimum zu erreichen.

Ein weiterer wichtiger Punkt in diesem AP ist das adaptiv-prädiktive Regelungsschema, welches sowohl auf lineare wie auch nichtlineare (Fuzzy) Schemen angewandt werden kann. In Abb. 9 ist dieses adaptive Schema in einem Blockschaltbild dargestellt.




Abbildung 10: Blockschaltbild eines adaptiv-prädiktiven Regelungsschemas.

In Abb. 10 sieht man sehr gut, dass der modellprädiktive Regler (MPC) in einer Schleife immer wieder neu entworfen wird. Der MPC generiert eine Stellgröße „u“ welche sowohl in das reale Gebäude eingeht wie auch in den Modellierungsalgorithmus. Aus dieser Stellgröße ergibt sich im Gebäude (pro Zone) eine gewisse Raumtemperatur „y“, diese wird ebenso in den Identifikationsalgorithmus gespeist. Die Systemidentifikation erhält in jedem Zeitschritt die Eingangsdaten, die zu einer gewissen Raumtemperatur (Ausgang y) führen. Anhand dieser Information wird der Prozess der in Kapitel 3.1.3 beschrieben wurde wiederholt, getestet, analysiert und das beste Modell wird nun für das Reglerdesing verwendet. Dieser Algorithmus benötigt eine gewisse Zeit bis die Parameter des Modells / des Reglers konvergieren. Sobald eine stationäre Lösung (je für Sommer, Winter, Übergang) erreicht ist läuft der MPC robust und die Umschaltung der Modelle kann in einem Schritt durchgeführt werden.

3.3 Adaptive Datenverknüpfung

Im vorherigen Kapitel wurde bereits erörtert wie adaptiv das beste Modell ausgewählt werden kann ohne, dass die NutzerInnen etwas machen müssen. Das gleiche Prinzip, dass die NutzerInnen keine aktiven Aktionen durchführen müssen, wird für den Aufbau einer Wissensbasis über das NutzerInnen-Verhalten genutzt.

Dazu wird mittels adaptiver Verknüpfungen aus den passiv zur Verfügung stehenden NutzerInnen-Daten eine Wissensbasis aufgebaut. Die Grundidee der adaptiven Datenverknüpfung ist in Abb. 11 dargestellt.




Abbildung 11: Darstellung adaptiver Datenverknüpfung.

Hierbei ist die wünschenswerte Wissensbasis nicht nur die individuellen Komforttemperaturen und NutzerInnen-Eigenheiten, sondern auch die zu erwartenden Anwesenheiten. Diese Präsenzdaten sind ein integrativer Bestandteil des Reglers und sollten ohne Eingaben der NutzerInnen ermittelt werden. Der dazu entwickelte Algorithmus ermöglicht aus den gesammelten vergangenen Präsenzdaten und der aktuellen Anwesenheit eine Prädiktion über die zukünftige Anwesenheit zu generieren. Dies geschieht vollautomatisch ohne Eingaben von den NutzerInnen (siehe Publikationen [5] und [6]). Dazu werden die gesammelten Präsenzdaten mittels einer POD (proper orthogonal decomposition) in grundlegende Features zerlegt. Diese Features geben dann das Benutzerverhalten bestmöglich wieder. In Abbildung 12 sind 4 Features dargestellt. Die bunten Linien im Hintergrund sind die gesammelten Präsenzdaten, und die extrahierten Features sind als φ_1 bis φ_4 eingezeichnet. Es ist leicht zu erkennen, dass Feature 1 einer Person entspricht die Vollzeit arbeitet (Abwesenheit unter Tags), während Feature 3 und 4 einer Person die Halbtags arbeitet. Feature 2 ist ein Feature wo keine genaue Aussage über die Anwesenheit getroffen werden kann (z.B. Feiertag, Wochenende).




Abbildung 12: Feature-Erkennung mittels POD.

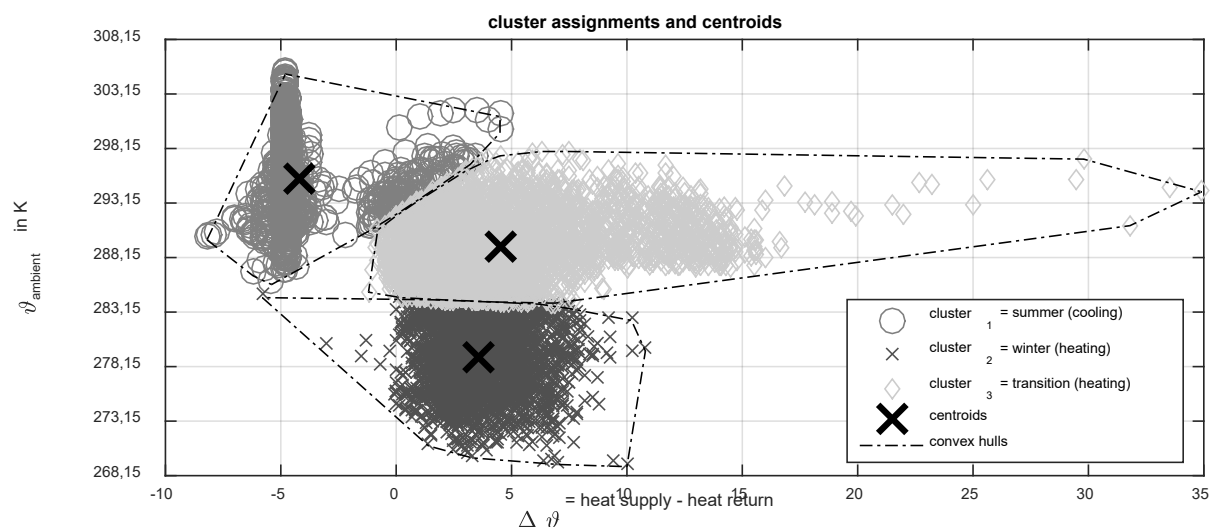


Abbildung 13: Möglichkeit eines Clusteringverfahren für Gebäudedaten.

In Abb. 13 sieht man eine Möglichkeit Gebäudedaten in 3 große „Bereiche“ zu clustern bzw. zu klassifizieren. Man sieht auf der Ordinatenachse die Außentemperatur über ein Jahr in Kelvin gemessen, auf der Abszisse ist die Differenz zwischen Vor- und Rücklauf einer Betonteilaktivierung aufgetragen. Man sieht sehr schön, dass automatisch in Sommer, Winter, Übergangszeit geteilt wird. Die Winterdaten sind durch die dunkelgrauen Daten gekennzeichnet, während der Sommerbereich mit mittelgrauen Kreisen dargestellt wurde. Der hellgraue Bereich definiert die Übergangszeit, in der hauptsächlich geheizt wird, die Außentemperaturen allerdings nicht mehr deutlich im Winterbereich liegen, sondern in der Nähe des Schwellenwerts (siehe Abb. 6).

Das User-Interface wurde designed und in den Regelungskonzept implementiert. Ein besonderer Focus lag an der Einfachheit und intuitiven Bedienbarkeit. Dies ist wichtig, damit auch Personen die nur ein geringes Hintergrundwissen über Heizungssysteme haben den Regler an ihren individuellen Bedürfnissen anpassen können. Eine genauere Beschreibung des User-Interface ist im Kapitel 4 und in Abbildung 16 gegeben.

4 Ergebnisse und Schlussfolgerungen

Es wurde sowohl das Gebäude selbst, als auch das NutzerInnenverhalten adaptiv modelliert. Spezielle Algorithmen wurden entwickelt um die optimalen Modelle für jegliche Situation automatisch auszuwählen ohne, dass die NutzerInnen etwas davon merken. Die Robustheit der Methode wurde anhand von mehreren Simulationen gezeigt und wurde in [2-5] publiziert.

Die Publikation [2] beleuchtet hierbei speziell die kurzzeitige Vorhersage der Anwesenheit von NutzerInnen in Smart-Homes welche aus den vergangenen NutzerInnen-Daten selbständig gelernt wurde.

In der Publikation [3] wurde sogar ein Modell vorgestellt wie die Wetterprädiktionen adaptiv angepasst werden können um verbesserte Vorhersagen zu generieren.

In [4] wird die Wichtigkeit der Anwesenheits-Prädiktion noch einmal genauer erörtert und das Clustering (zusammenfassen von ähnlichen NutzerInnen) exemplarisch vorgezeigt. Außerdem wurde das Grundprinzip des adaptiven MPC in der Arbeit formuliert.

Mithilfe einer in [5] vorgestellten dynamischen Kalman Filter-Bank kann diskret das optimale Gebäudemodell gewählt werden um eine energieoptimalen MPC zu betreiben. Abbildung 14 illustriert diese Vorgangsweise. In der gleichen Publikation wurde ebenfalls ein Fuzzy-MPC vorgestellt. Dieser Fuzzy-MPC besteht aus einer Kombination von mehreren MPC mit unterschiedlichen Modellen. Je nach der Optimalität der einzelnen Gebäudemodelle kann mittels nicht-linearer Logik ein neuer Ausgang berechnet.

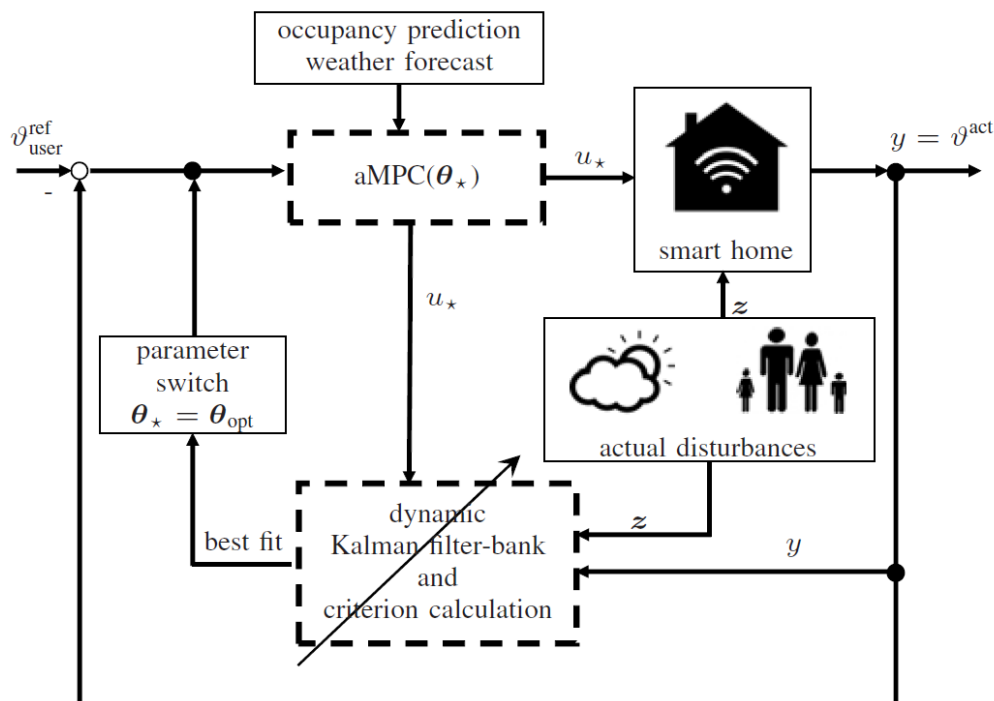


Abbildung 14: MPC mit Kalman Filter-Bank. Die Kalman Filter-Bank erzeugt die optimalen Parameter θ_{opt} , welche den MPC das optimale Gebäudemodell anzeigen.

Im Laufe des Projektes wurden zahlreiche Simulationen mit unterschiedlichen Referenzmodellen und (angenommen) Modellierungsfehlern angefertigt um die Robustheit des Regelkonzeptes zu testen. Die ausführlichen Ergebnisse dieser Studie sind in der Publikation [9] ersichtlich.

Ebenfalls wurden der Einfluss der Gewichtung der Regelziele mittels Simulationen untersucht, sowie der Einfluss der Vorhersagen-Genauigkeit auf die Performance. Tabelle 1 gibt den Einfluss der Vorhersage-Genauigkeit für eine 7 tägige Simulation wieder. Hierbei bezeichnet „Wetterdienst“ die Online-Vorhersagen eines Wetterservice und „Verbessert“ die lokalisierten Vorhersagen (siehe [3,9]). Die Vorhersage-Methode „Perfekt“ bezeichnet den theoretischen Fall in dem der MPC perfekte Vorhersagen zur Verfügung gehabt hätte.

Tabelle 1: Einfluss der Vorhersage-Genauigkeit auf die MPC Performance.

Vorhersage-Methode	Konsumierte Energie	Temperatur-Fehler (RMSE)	Laufende Kosten
Wetterdienst	123kWh	0.19°C	4.54€
Verbessert	123kWh	0.16°C	4.53€
Perfekt	119kWh	0.08°C	4.4€

Ein weiterer Kernpunkt des Projektes war es den MPC mit zeitvarianten Gewichtungen auszustatten. Dies hat zur Folge, dass der MPC verschiedene Strategien über den Vorhersagehorizont verfolgen kann. Diese unterschiedlichen Strategien können z.B. sein, dass der MPC den thermalen Komfort sehr viel stärker gewichtet zu Zeiten wo NutzerInnen anwesend sind und mehr auf eine Energieeinsparung forciert ist zu Zeiten wo keiner Anwesend ist. Um die Vorteile dieser variablen Gewichte zu illustrieren wurden mehrere Simulationen angefertigt. Die Publikation [6] behandelt die unterschiedlichen Vorgangsweisen des MPC wenn thermaler Komfort gewünscht wird und stellt diese den Vorgangsweisen gegenüber wenn eine energieminimierende Betriebsweise verlangt wird. Abbildung 15 zeigt diese Unterschiede: Die rote Linie entspricht der Innentemperatur bei einer Betriebsweise wo maximaler thermaler Komfort gefordert wird. Es ist ersichtlich, dass die rote Linie immer in der Nähe der Referenztemperatur (strichlierte Linie) ist. Die grüne Linie entspricht einem Szenario bei dem minimaler Energieverbrauch gewünscht wird. Deutlich zu erkennen ist das Absenken der Innentemperatur zu Zeiten in denen die NutzerInnen abwesend sind. Die blaue Linie zeigt den Verlauf der Temperatur an falls minimale Kosten priorisiert werden. Auch hier ist eine Absenkung während der Abwesenheit ersichtlich.

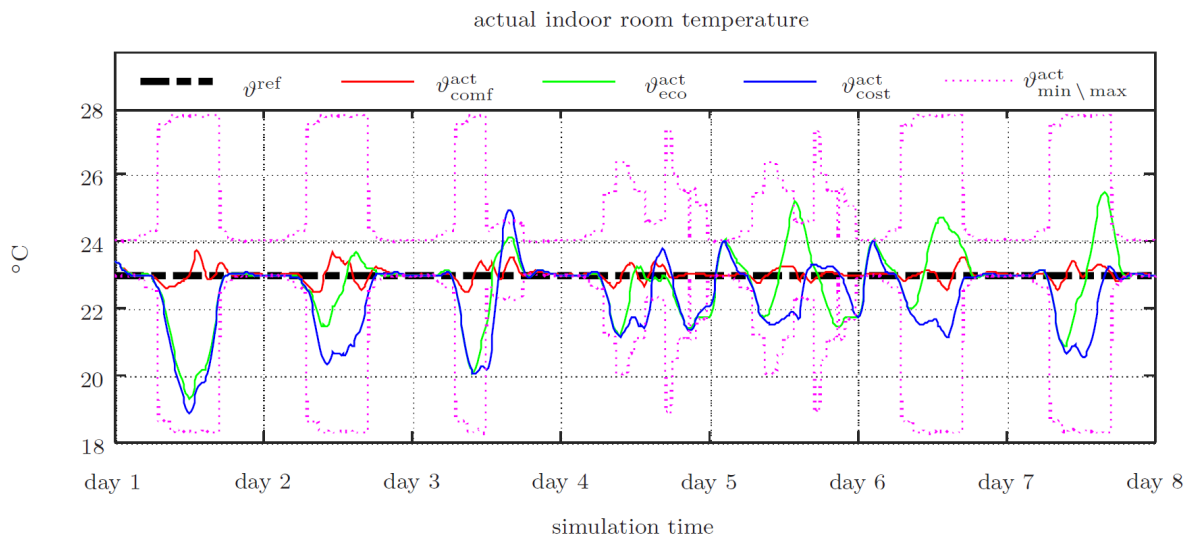


Abbildung 15: Simulierte Innentemperatur des Smart-Homes bei verschiedenen Betriebsweisen.

In den Publikationen [7-8] werden die Gewichte und Optimierungshorizonte noch einmal beleuchtet. Hierbei beschäftigt sich [7] mehr mit den Grundlagen und [8] stellt eine Erweiterung für Mixed-Integer MPC dar.

Der entwickelte prädiktive Heizungs-Regler wurde erfolgreich in einem Testgebäude implementiert. In der implementierten Variante verwendete der Heizungsregler hochauflösende Wettervorhersagen und ein vorher gelerntes NutzerInnen-Verhalten. Die Wettervorhersagen wurden aus dem Internet geladen und umfassten Außentemperatur sowie einfallende Solarstrahlung. Aus dem gelernten NutzerInnen-Verhalten wurden Vorhersagen über die zukünftige Anwesenheitswahrscheinlichkeit der Bewohner erstellt. Um die Robustheit des prädiktiven Heizungs-Reglers zu zeigen wurde bewusst ein einfaches und universell anwendbares Gebäudemodell gewählt. Dies verdeutlicht, dass der Heizungs-Regler auf eine große Bandbreite von unterschiedlichen Gebäuden angewandt werden kann und die Güte des Modells keinen großen Einfluss auf die Performance des Reglers hat. Vielmehr hat sich gezeigt, dass die Güte der benötigten Prädiktionen einen größeren Einfluss auf die Performance hat, als die Modelgüte.

Das Heizungssystem des Gebäudes wurde als elektrischer Wärmepumpe modelliert. Jedoch ist der prädiktive Heizungs-Regler ohne Probleme in der Lage mit andere Heizungssysteme verwendet zu werden.

Um die Modularität des entwickelten Heizungs-Reglers zu zeigen wurden ebenfalls eine virtuelle Batterie und eine virtuelle Photovoltaik-Anlage emuliert. Im Testgebäude wurde dafür zusätzlich ein Smart-Meter zur Echtzeit-Verbrauchsmessung eingebaut. Die benötigten Prädiktionen für zukünftige PV-Energieproduktion wurden ebenfalls über das Internet geladen. Durch die Erweiterung des prädiktiven Heizungs-Reglers mit einer alternativen Energiequelle und eines elektrischen Speichers können weitere energiesparende Optimierungs-Strategien verfolgt werden. So kann z.B. der Heizungs-Regler unter tags das Gebäude überheizen, wenn die PV-Anlage mehr Energie produziert als benötigt wird und keine Bewohner anwesend sind. Dieses überheizen ermöglicht die thermischen Speicherkapazitäten des Hauses zusätzlich zu den Speicherkapazitäten der Batterie zu verwenden (siehe Publikation [6]).

Ein weiterer Vorteil der Erweiterung des prädiktiven Heizungs-Reglers mit den elektrischen Komponenten ist, dass der Regler 3 Ziele verfolgen kann. Diese sind teilweise widersprechende Ziele sind:

1. Maximaler NutzerInnen-Komfort
2. Minimaler Energieverbrauch
3. Minimale laufende Kosten

Der Endbenutzer kann über das Benutzerinterface (siehe Abb. 16) nahtlos zwischen diesen Zielen wählen. Dazu wird der Endbenutzer aufgefordert einen Punkt im Inneren des Dreiecks zu wählen. Je näher der Punkt an einer der Ecken ist, desto mehr wird dieses Ziel priorisiert.




Abbildung 16: Graphisches Endbenutzer-Benutzerinterface mit den 3 Zielen in den Ecken. „Comf“ ist der maximale NutzerInnen-Komfort, „Eco“ ist der minimale Energieverbrauch, „Costs“ sind die minimalen laufenden Kosten. Der Endbenutzer wählt einen Punkt im Inneren des Dreiecks aus um den prädiktiven Heizungs-Regler individuell zu tunen.

Nach einem rund 1-monatigen Testlauf zur Validierung der Funktionalität des Programms und der Schnittstellen wurden 2 längere Datensätze hintereinander gesammelt.

Der erste Datensatz ist 9 Tage lang und dient als Vergleichsdatsatz. In diesen Datensatz war der prädiktive Heizungs-Regler nicht aktiv, sondern es wurde der hausinterne state-of-the-art Regler verwendet. Jedoch wurde parallel die Ausgänge des prädiktiven Heizungs-Reglers gerechnet um einen sanity-check auszuführen.

Der zweite Datensatz ist 8.5 Tage lang und während dieser Zeit war der prädiktive Heizungs-Regler aktiv. In diesem Zeitraum hat der prädiktive Heizungs-Regler die Vorlauftemperatur des verbauten Heizungssystems geregelt. Dabei wurde das Ziel des maximalen Benutzerkomforts priorisiert (im graphischen Benutzerinterface wurde die rote Ecke „Comf“ gewählt). Es hat sich gezeigt, dass der prädiktive Regler die Innentemperatur im Gebäude mindestens so gut halten kann wie der hausinterne

Energieforschungsprogramm - 02. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

state-of-the-art Regler. Die Ergebnisse aus den zwei Datensätzen sind in Abb. 17 ersichtlich. Mit einem besser optimierten Modell des Gebäudes wäre mit einer Verbesserung der Performance zu rechnen.

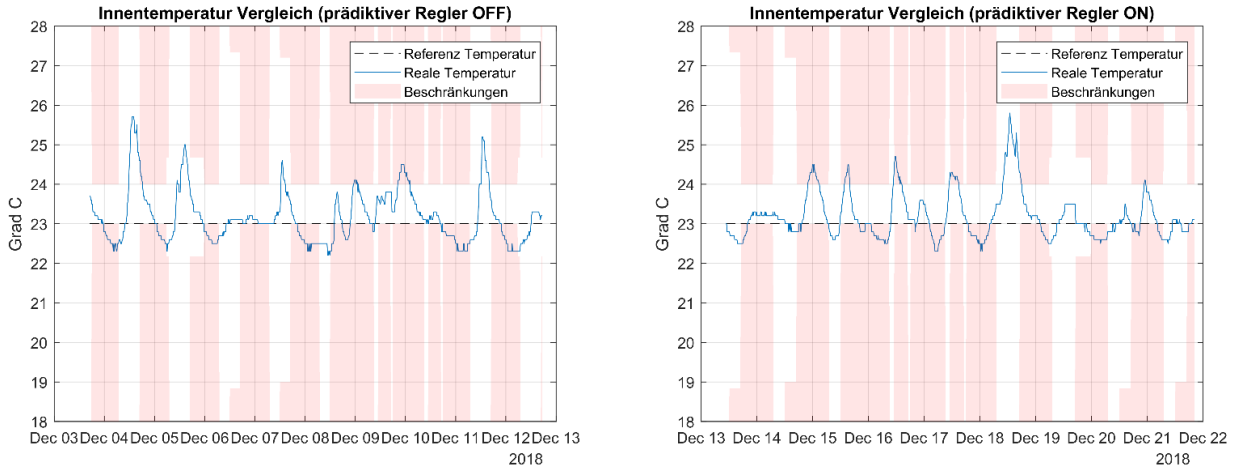


Abbildung 17: Vergleich der Innentemperatur vom ersten Datensatz (links, ohne prädiktiven Regler) und zweiten Datensatz (rechts, mit prädiktivem Regler). In rot sind die Temperaturbeschränkungen eingezeichnet die mit der Belegung des Gebäudes korrelieren.

Wie bereits vorher erwähnt, wurden ebenfalls eine virtuelle Batterie und eine PV-Anlage emuliert. Der prädiktive Heizungs-Regler regelte wann die Batterie geladen oder entladen wurde. Weiters wurde angenommen, dass der prädiktive Heizungs-Regler in der Lage ist vom Stromnetz Energie zu kaufen, oder wenn überschüssige Energie vorhanden ist, diese an das Stromnetz zu verkaufen. Es wurde pauschal angenommen, dass der Preis um Energie aus dem Stromnetz zu kaufen doppelt so hoch ist wie der Ertrag der Erzielt wird, wenn an das Netz Energie verkauft wird.

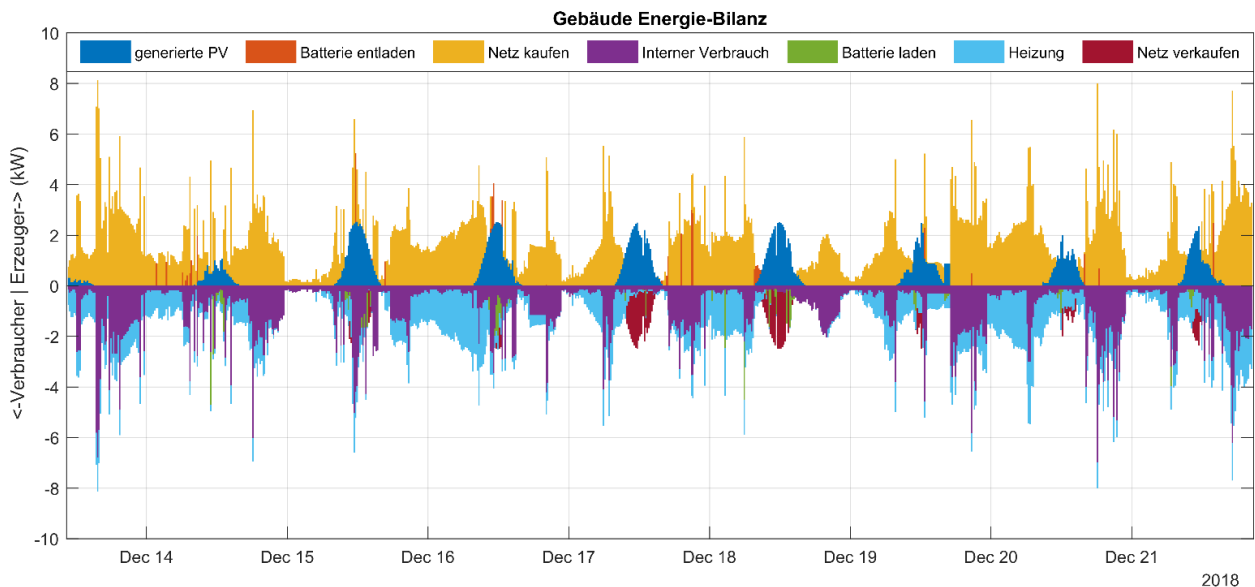


Abbildung 18: Energie-Bilanz des Gebäudes während der Zeit wo der prädiktive Heizungs-Regler aktiv ist. Der „interne Verbrauch“ ist jene Energie die das Gebäude und die NutzerInnen verbraucht haben. „Heizung“ ist jener Energieaufwand der für die elektrische Wärmepumpe aufgewendet wird.

Die Energie-Bilanz während der Zeit wo der prädiktive Heizungs-Regler aktiv war (2.Datensatz) ist in Abb. 18 dargestellt. Dadurch, dass der prädiktive Heizungs-Regler nur auf maximalen BenutzerInnen-Komfort getunt war, wurde keine Energieeinsparung im Vergleich zum Vergleichsdatensatz erzielt. Außerdem wurde die Batterie nur selten verwendet. Dies ist vor allem auf die schlechte Prädiktion des internen Energie-Verbrauches sowie auf die Unsicherheiten bei der Prädiktion des PV-Energieertrages zurückzuführen. Bei einer Simulation mit den Datensatz und perfekten Prädiktionen für den internen Verbrauch wird eine 20% höhere Batterieauslastung erzielt. Wenn ebenfalls perfekte Prädiktionen für den PV-Energieertrag verwendet werden wird sogar eine 90% höhere Batterieauslastung erzielt. Auch bei der Verwendung eines anderen Endbenutzer-Tunings, wie z.B. die gleiche Gewichtung der 3 Ziele (= Mitte des graphischen Endbenutzer-Interface) und verbesserten Prädiktionen wird eine höhere Batterieauslastung erzielt. Hier wurde bei Verwendung der perfekten Prädiktionen für internen Verbrauch und PV-Energieertrag eine 107% höhere Batterieauslastung erzielt als im Vergleich zu den originalen Prädiktionen.

Bei der Verbesserung der Prädiktionen für Außentemperatur und Sonneneinstrahlung ist der Effekt nicht ganz so stark ausgeprägt. Dies liegt vor allem daran, dass das thermische Modell des Gebäudes bereits Ungenauigkeiten aufweist und eine verbesserte Prädiktion deshalb nur ein geringer Genauigkeitszuwachs erzielen kann. Jedoch konnte der MAE der Innentemperatur um 9% reduziert werden und der MSE sogar um 25%.

Bei dem Weglassen der relativ kleinen Batterie (6.54 kWh) werden 8% höhere Strom-Kosten simuliert.

5 Ausblick und Empfehlungen

Mit dem heutigen Stand der Technik kann zurzeit keine Verknüpfung der elektrischen Komponenten und der thermischen Komponenten unter einen gemeinsamen globalen Regler sinnvoll erreicht werden. Der Hauptgrund dafür liegt vor allem daran, dass es keine allgemeine Schnittstelle für die einzelnen Komponenten existiert. So ist es z.B. zurzeit nicht möglich einem handelsüblichen elektrischen Energiespeicher für Smart-Homes extern anzusteuern. Mit einer voranschreitenden Automatisierung in allen Bereichen und einer Ausbreitung von IoT (Internet of things) Technologien ist dies jedoch nicht nur denkbar, sondern sogar wahrscheinlich.

Moderne Smart-Homes besitzen bereits heute flächendeckend einen Internetzugang. Dieser Internetzugang ermöglicht den Abruf von Wetterprädiktionen und Solarvorhersagen. Außerdem möglich ist die Verwendung von Cloud-Computing Services um rechenintensivere Aufgaben zu bewältigen. Diese Aufgaben können zum Beispiel das Erkennen von NutzerInnenverhalten sein oder das Optimieren von den Gebäudemodellen.

Ebenfalls ist es wahrscheinlich, dass smarte Gebäude in Zukunft miteinander Verknüpft sind und in smarten Grids zusammengefasst werden. Diese smarten Grids planen den Energieverbrauch der steuerbaren smarten Geräte so, dass es zu keinen Lastspitzen kommt. Dies ermöglicht eine ressourcenschonendere Verwendung der Energieerzeugungskapazitäten indem sich die Verbraucher an die vorhandenen Kapazitäten orientieren und diese untereinander aufteilen.

Sowohl für die Verknüpfung der gebäudeinternen Komponenten und der übergeordneten Verknüpfung der einzelnen Gebäude in smarte Grids muss eine einheitliche Schnittstelle geschaffen werden, welche es ermöglicht Daten (Vorhersagen, Randbedingungen, ...) untereinander auszutauschen. Um die flächendeckende Verbreitung von vernetzten Smart-Homes voranzutreiben (Neubauten, sowie Retrofitting) müssen monetäre Anreize von den smart Grid Betreibern angeboten werden. Diese Anreize können reichen von Gutschriften, Kauf von lokal produzierter alternativer Energie bis hin zur Strafzahlungen bei netzbelastender Betriebsweise.

Neben den zukünftigen monetären Anreizen bieten fortschrittliche Regler für Smart-Homes bereits heute ein Kosteneinsparungspotential bei dem Energieverbrauch für Heizungs- und Kühlsysteme. Weitere Vorteile von Smart-Homes sind der verbesserte Komfort und die zusätzlichen Sicherheitsaspekte, jedoch stehen diese meist hohen Investitionskosten gegenüber. Bei einer höheren Marktabdeckung und der damit verbundenen höheren Stückzahlen ist mit niedrigeren Investitionskosten in der Zukunft zu rechnen. Falls ebenfalls smart Grids geschaffen werden kann es in der Zukunft sogar rentabel sich für ein Smart-Home zu entscheiden.

6 Literaturverzeichnis

- [1] M. Killian, M. Kozek, A. Leitner, R. Goldgruber. *IntelliEE-Home: Intelligent energy-efficient home automation system*. In Proc. of International Congress e-nova: Nachhaltige Gebäude: Versorgung - Speicherung - Optimierung", November 26/27 2016, Pinkafeld, Austria, ISBN: 978-37011-0372-0.
- [2] M. Killian, and M. Kozek. Adaptive modelling and short-term occupancy prediction for model predictive control of smart homes. In Proc. of IFAC workshop on Control of Smart Grid and Renewable Energy Systems, June 10–12, 2019, Jeju Island, South Korea, submitted.
- [3] M. Zauner, M. Killian, M. Kozek. Localized Online Weather Predictions with Overnight Adaption; In Proc. of International Conference on Time Series and Forecasting (ITISE 2018), September 19 -21, 2018, Granada, Spain.
- [4] M. Killian, M. Kozek, A. Leitner, and R. Goldgruber. Short-term forecasts for optimal model predictive control in smart homes. In Proc. of International Congress e-nova: "Zukunft der Gebäude: digital – dezentral – ökologisch", November 23–24, 2017, Pinkafeld, Austria.
- [5] M. Killian, M. Kozek. Adaptive model predictive control for energy-efficient smart homes using a dynamic Kalman filter-bank. In Proc. the 15th International Conference on Control, Automation, Robotics and Vision (ICARCV 2018), November 18 – 21, 2018, Singapore, IEEE, accepted for presentation.
- [6] M. Killian, M. Zauner, and M. Kozek. Comprehensive smart home energy management system using mixed-integer quadratic-programming; *Applied Energy*, 222 (2018), S. 662 - 672.
- [7] M. Killian, M. Kozek, A. Leitner, R. Goldgruber. Optimization of smart homes using mixed-integer quadratic-programming and occupancy predictions. In Proc. of 8th International Symposium on Energy August 06 – 09, 2018, Aberdeen, Scotland, UK (invited), North Sea Conference & Journal.
- [8] M. Killian, A. Leitner, R. Goldgruber, and M. Kozek. Adaptive model predictive control for energy-efficient smart homes. In Proc. of 7th International Symposium on Energy, August 13–18, 2017, Manchester, England, UK (invited), North Sea Conference & Journal.
- [9] M. Zauner. Global Predictive control for smart homes using improved disturbance predictions. Betreuer/in(nen): M. Kozek, M. Killian; Institut für Mechanik und Mechatronik, 2018; Diplomarbeit; Abschlussprüfung: 06.03.2018.

7 Anhang

8 Kontaktdaten

A.o.Univ. Prof. DI Dr. Martin Kozek

Technische Universität Wien

Institut für Mechanik und Mechatronik

Abteilung für Regelungstechnik und Prozessautomatisierung

Karlsplatz 13, 1040 Wien. Tel: (+43-1) 58801/325-512. E-Mail: martin.kozek@tuwien.ac.at

DI Dr.techn. Michaela Killian

Technische Universität Wien

DI Michael Zauner

Technische Universität Wien

DI Andreas Leitner

Evon Automation GmbH

DI Robert Goldgruber

Evon Automation GmbH