




Schlussbericht vom 18. April 2024

GIASES

Ganzheitlich Integrierendes Adaptives Smart Energy System zur Glättung von Lastspitzen



Quelle: © HSLU



Datum: 18. April 2024

Ort: Bern

Subventionsgeberin:

Bundesamt für Energie BFE
Sektion Energieforschung und Cleantech
CH-3003 Bern
www.bfe.admin.ch

Subventionsempfänger/innen:

Hochschule Luzern Technik & Architektur
Technikumstrasse 21
6048 Horw
<https://www.hslu.ch>

ASGAL Informatik GmbH
Fürschtweg 20
8880 Walenstadt
<https://asgal.ch>

Autor/in:

Guido Kniesel, HSLU, guido.kniesel@hslu.ch
Andreas Melillo, HSLU, andreas.melillo@hslu.ch
Manuel Meyer, HSLU, manuel.meyer@hslu.ch
Philipp Schütz, HSLU, philipp.schuetz@hslu.ch
Reto Hendry, HSLU, reto.hendry@hslu.ch
Thomas Gall, ASGAL Informatik GmbH, thomas.gall@asgal.ch

BFE-Projektbegleitung:

Karin Söderström, karin.soederstroem@bfe.admin.ch
Roland Brüniger, roland.brueeniger@brueniger.swiss
Michael Moser, michael.moser@bfe.admin.ch

BFE-Vertragsnummer: SI/502319-01

Für den Inhalt und die Schlussfolgerungen sind ausschliesslich die Autoren dieses Berichts verantwortlich.



Zusammenfassung

Das Ziel des Projektes GIASES war es, in einer realen Netzumgebung mit mehreren Tausend Messpunkten (Standard Smart-Meter mit 15 min Auflösung) mittels eines ganzheitlich integrierenden Ansatzes ein adaptives System zum Glätten von Lastspitzen zu erproben, um den Bedarf an Netzverstärkung zu reduzieren. Hierzu wurde in einem breit angelegten Feldtest ein intelligentes Energiemanagement- und Verbrauchsplanungssystem getestet und beurteilt. Basierend auf den Echtzeitdaten der teilnehmenden Netzbetreiber (Ebenen 5-7) wurden durch Analyse und Ansteuerung von flexiblen Verbrauchern wie Wärmepumpen, Boilern und E-Ladestationen Lastspitzen geglättet, indem Energieproduktion und -verbrauch prognostiziert und aufeinander abgestimmt wurden.

Die Gerätetypenkenntung und Disaggregation von Lastkurven durch adaptierte und neu entwickelte Algorithmen haben gute Ergebnisse in der präzisen Identifizierung von Photovoltaikanlagen, Wärmepumpen, Boilern und E-Ladestationen erzielt, trotz Herausforderungen wie der falschen Erkennung in spezifischen Konfigurationen. Die Vorhersage des Verhaltens von Wärmepumpen im Hinblick auf Wärmebedarf, Warmwasser und Gesamtverbrauch zeigt, dass eine hohe Genauigkeit für Flexibilitäts-Anwendungsfälle erreicht werden kann. Auch die Optimierungen in der Verbrauchsplanung zeigen, dass durch den Einsatz flexibler Komponenten und entsprechender Steuerungsstrategien erhebliche Lastspitzenreduktionen und Effizienzsteigerungen möglich sind, insbesondere durch eine gezieltere und effizientere Gruppierung von Flexibilitäten sowie der gestaffelten Abschaltung von privaten E-Ladestationen zwischen 17 und 21 Uhr. Insgesamt zeigt das Projekt, dass durch die intelligente Analyse, Vorhersage und Steuerung von Energieverbräuchen nicht nur die Effizienz gesteigert, sondern auch signifikante Beiträge zur Netzstabilität und zur Reduktion von Netzausbaubedarfen geleistet werden können.

Résumé

L'objectif du projet GIASES était de tester, dans un environnement de réseau réel comportant plusieurs milliers de points de mesure (compteurs intelligents standard avec une résolution de 15 min), un système adaptatif de lissage des pics de charge au moyen d'une approche intégrative globale, afin de réduire le besoin de renforcement du réseau. Pour ce faire, un système intelligent de gestion de l'énergie et de planification de la consommation a été testé et évalué dans le cadre d'un essai sur le terrain à grande échelle. En se basant sur les données en temps réel des gestionnaires de réseau participants (niveaux 5 à 7), l'analyse et la commande de consommateurs flexibles tels que les pompes à chaleur, les chauffe-eau et les stations de recharge électrique ont permis de lisser les pics de charge en prévoyant la production et la consommation d'énergie et en les coordonnant.

La détection du type d'appareil et la désagrégation des courbes de charge par des algorithmes adaptés et nouvellement développés ont donné de bons résultats dans l'identification précise des systèmes photovoltaïques, des pompes à chaleur, des chauffe-eau et des stations de recharge électrique, malgré des défis tels que la mauvaise détection dans des configurations spécifiques. La prédiction du comportement des pompes à chaleur en termes de demande de chaleur, d'eau chaude et de consommation totale montre qu'une grande précision peut être atteinte pour les cas d'application de la flexibilité. Les optimisations de la planification de la consommation montrent également qu'il est possible de réduire considérablement les pics de charge et d'augmenter l'efficacité grâce à l'utilisation de composants flexibles et de stratégies de contrôle appropriées, notamment grâce à un regroupement plus ciblé et plus efficace des flexibilités et à la déconnexion échelonnée des stations de recharge électriques privées entre 17 et 21 heures. Dans l'ensemble, le projet montre que l'analyse, la prévision et le contrôle intelligents des consommations d'énergie permettent non seulement d'augmenter l'efficacité, mais aussi de contribuer de manière significative à la stabilité du réseau et à la réduction des besoins d'extension du réseau.

Summary

The aim of the GIASES project was to test an adaptive system for smoothing load peaks in a real grid environment with several thousand measuring points (standard smart meter with 15 min resolution) using a holistic, integrative approach to reduce the need for grid reinforcement. To this end, an intelligent energy management and consumption planning system was tested and evaluated in a large-scale field test. Based on real-time data from the participating grid operators (levels 5-7), load peaks were smoothed by analysing and controlling flexible consumers such as heat pumps, boilers and e-charging stations by forecasting and coordinating energy production and consumption.

Device type detection and disaggregation of load curves through adapted and newly developed algorithms have achieved good results in the precise identification of photovoltaic systems, heat pumps, boilers and e-charging stations, despite challenges such as false detection in specific configurations. Predicting the behaviour of heat pumps in terms of heat demand, hot water and total consumption shows that a high level of accuracy can be achieved for flexibility use cases. The optimisations in consumption planning also show that the use of flexible components and corresponding control strategies can significantly reduce peak loads and increase efficiency, particularly through a more targeted and efficient grouping of flexibilities and the staggered shutdown of private e-charging stations between 5 and 9 pm. Overall, the project shows that the intelligent analysis, prediction and control of energy consumption can not only increase efficiency, but also make a significant contribution to grid stability and reduce the need for grid expansion.



Take-home messages

- Die Erkenntnisse aus dem Feldtest zeigen:
 - Wenn die privaten Ladestationen gemäss Werkvorschriften bei Bedarf zwischen 17 und 21 Uhr gestaffelt abgeschaltet werden, können dadurch Engpässe bei einzelnen Transformatorenstationen vermieden werden.
 - Eine gezieltere Gruppierung von Boilern ermöglichen eine effektivere Ansteuerung.
 - Für Wärmepumpen fehlt derzeit noch eine standardisierte Ansteuerung (SmartGridready) von Einzelkomponenten. Exemplarische Tests mit proprietären Schnittstellen von Wärmepumpen zeigen die prinzipielle Wirksamkeit des SES für Lastspitzenreduktion, was einen wirksamen Beitrag zur Reduzierung des Bedarfs an Netzausbau ermöglicht.
- Das GIASES Smart Energy System (SES) ermöglicht die zuverlässige Detektion und Disaggregation von Photovoltaik und der Flexibilitätskomponenten Wärmepumpen, Boiler, E-Ladestationen und Batterien aus Standard 15 Minuten Smart-Meter Daten.
- Die Genauigkeit der Vorhersage-Algorithmen für die Komponenten Wärmebedarf, Warmwasser- und Gesamtverbrauch ermöglichen deren Einsatz in Flexibilitätsanwendungen.
- Die Resultate aus der Disaggregation und Vorhersage erlauben eine gezieltere und effizientere Gruppierung von Flexibilitäten.



Zusammenfassung	3
Résumé	3
Summary	4
Take-home messages	5
1 Einleitung	8
1.1 Ausgangslage und Hintergrund	8
1.2 Motivation des Projektes	8
1.3 Projektziele	8
2 Anlagenbeschrieb	10
2.1 Übersicht Smart Energy System (SES)	10
2.2 SES Web-Plattform	11
2.3 Detektion von Flexibilitäten	12
2.4 Disaggregation	13
3 Vorgehen und Methode	15
3.1 Inbetriebnahme Infrastruktur	15
3.2 Aufbereitung der Messdaten	15
3.3 Gerätetyperkennung	16
3.4 Disaggregation / Lastgangerkennung	17
3.5 Vorhersage von Verbrauchsspuren	23
3.6 Flexibilitätslabel / Haustyperkennung	24
3.7 Lastverschiebung / Ansteuerung	24
4 Ergebnisse und Diskussion	26
4.1 Inbetriebnahme Infrastruktur / Aufbereitung der Messdaten	26
4.2 Feldtest	26
4.3 Gerätetyperkennung	26
4.4 Disaggregation / Lastgangerkennung	27
4.5 Vorhersage	29
4.6 Flexibilitätslabel / Haustyperkennung	38
4.7 Lastverschiebung / Ansteuerung	42
4.8 Weitere Erkenntnisse	44
4.8.1 Ansteuerbare Wärmepumpe (via Herstellerschnittstelle)	44
4.8.2 Vergleichsanalyse Anschlussgesuche mit Ergebnissen der Algorithmen	45
4.8.3 Generisches Einsparpotential Netzausbau	48
4.8.4 Vergleichsanalyse Netzplanungsgrundsätze mit Algorithmen	50
4.9 Interaktionen mit den Verteilnetzbetreibern (VNB)	50
5 Schlussfolgerungen und Fazit	52
6 Ausblick und zukünftige Umsetzung	53
7 Nationale und internationale Zusammenarbeit	55



7.1	SmartGridready.....	55
7.2	ENFLATE.....	55
7.3	SWEET – PATHFNDR / EDGE.....	56
8	Anhang.....	57
8.1	Literaturverzeichnis.....	57
8.2	Abbildungsverzeichnis	58
8.3	Ergebnisse 7-fold cross validation Disaggregation Wärmepumpe.....	60



1 Einleitung

1.1 Ausgangslage und Hintergrund

Aus wirtschaftlichen, gesellschaftlichen und ökologischen Notwendigkeiten heraus besteht der Bedarf die Netzverstärkung zu minimieren. Lastspitzen hingegen erfordern höhere Netzkapazitäten und destabilisieren zudem die Netze, insbesondere zunehmend mit dem wachsenden Anteil an erneuerbaren Energien.

Um die Netzverstärkung zu minimieren, soll ein intelligentes Lastmanagement die in Haushalten und Betrieben bereits vorhandenen verschiebbaren grossen Verbraucher automatisiert identifizieren und nutzbar machen. Die Lastverschiebung kann mit diesen im Verteilnetz bereits installierten, verschiebbaren Verbrauchern realisiert werden, indem Wärmepumpen, Boiler und zukünftig auch vermehrt E-Ladestationen und Batterien vorausschauend gesteuert werden, ohne dass für die Bewohner ein Komfortverlust entsteht. Viele dieser Verbraucher stellen somit brachliegende Energiespeicher dar, können aktuell jedoch nur zu einem Bruchteil genutzt werden, da es i.d.R. keinen verlässlichen gesamtheitlichen Überblick aller vorhandenen Flexibilitäten gibt. Zudem verändern sich die Mengengerüste der Flexibilitäten fortlaufend, insbesondere mit zunehmender Geschwindigkeit in den kommenden Jahren aufgrund des digitalen Transformationsprozesses hin zur Energiewende sowie der steigenden Elektrifizierung der Mobilität und der Ablösung von auf fossilen Brennstoffen basierenden Heizungssystemen durch Wärmepumpen.

Nachfolgend sind die in dem P+D Projekt beteiligten EVUs aufgelistet:

- Centralschweizerische Kraftwerke AG (CKW), Luzern
- EWA-energieUri, Altdorf
- IBC Energie Wasser Chur, Chur
- Technische Betriebe Vilters-Wangs, Wangs
- WWZ Energie AG, Zug
- Energie Service Biel/Bienne, Biel (passiver Partner, ohne Messpunkte)

1.2 Motivation des Projektes

Hauptsächliche Motivation des Projekts ist die Reduzierung von Lastspitzen und den damit einhergehenden Kosteneinsparungen für die Netzbetreiber und EVUs und somit letztendlich auch für die Endkunden und die Gesellschaft insgesamt. Einsparungen ergeben sich aus der Reduzierung von Netzverstärkungsmassnahmen, der Vermeidung der hohen Abgeltungskosten bei erhöhtem Leistungsbezug durch Lastspitzen sowie bei der Kraftwerksoptimierung durch Einsparungen der gehandelten Energie aufgrund verbesserter Prognosen.

1.3 Projektziele

Ziel dieses Projekts ist es, in einer realen Netzumgebung mit einem ganzheitlich integrierenden Ansatz ein adaptives System zum Glätten von Lastspitzen zu erproben, um den Bedarf an Netzverstärkung zu reduzieren. Dazu soll in einem breit angelegten Feldtest ein intelligentes Energiemanagement- und Verbrauchsplanungssystem getestet und beurteilt werden.

Basierend auf den Echtzeitdaten der teilnehmenden Netzbetreiber (Ebenen 5-7) sollen durch Analyse und Ansteuerung von flexiblen Verbrauchern wie Wärmepumpen, Boilern und E-Ladestationen Lastspitzen geglättet werden, indem Energieproduktion und -verbrauch prognostiziert und aufeinander abgestimmt werden.



In Detail sollen folgende Ziele erreicht werden:

- Vorhersage und Reduktion von Lastspitzen
- Erkennung und Disaggregation von einzelnen und aggregierten PV-Anlagen, Wärmepumpen, Boilern, Elektro-Ladestationen und Batterien mittels Machine Learning Algorithmen
- Feststellung der Genauigkeit und Wirksamkeit der entwickelten Algorithmen (Validierung)
- Exploration von Lastverschiebealgorithmen für die Generierung von Vorschlägen zur Lastverschiebung
- Integration von virtuellen Messpunkten (Haushalten ohne Smart Meter) in die Lastvorhersage
- Analyse von Messdaten aus Trafostationen

2 Anlagenbeschreibung

2.1 Übersicht Smart Energy System (SES)




Abbildung 1: Übersicht Workflow Smart Energy System (SES)

Das Smart Energy System (SES) unterstützt die Energieversorgungsunternehmen (EVU) bei den Energiedaten-, Last- und Netz- Management Prozessen. Die Messwerte von Wärme-, Kälte-, Wasser- und Energie-Zählern werden kontinuierlich aufgezeichnet, aufbereitet und den unterschiedlichsten Workflows zur Verfügung gestellt.

Im GIASES Projekt wurde der Fokus speziell auf die Detektion von Flexibilitäten (Wärmepumpen, Boiler, Ladestationen, Batterien und PV-Anlagen) gelegt. Die detektierten Flexibilitäten werden disaggregiert und anschliessend zu einem virtuellen Lastgang pro Flexibilitätstyp aggregiert.




Abbildung 2: Virtueller Lastgang aller disaggregierten Wärmepumpen

Der aggregierte Lastgang bildet die Grundlage für die Prognose pro Flexibilität.




Abbildung 3: Virtueller Lastgang aller PV-Anlagen im Verteilnetz

Die Produktion aller PV-Anlagen wird anhand von Referenzanlagen berechnet und ermöglicht den effektiven Gesamtverbrauch im Verteilnetz zu ermitteln.

2.2 SES Web-Plattform




Abbildung 4: Web-Plattform GIASES Smart Energy System

Das Smart Energy System (SES) Cockpit vermittelt den Mitarbeitern der Energieversorgungsunternehmen eine schnelle Übersicht über die aktuell laufenden Prozesse.

2.3 Detektion von Flexibilitäten

Der SES-Service scannt wöchentlich sämtliche Smart-Meter Lastgänge im Verteilnetz nach Flexibilitäten. In der Analyse-Übersicht können die Ergebnisse nach den verschiedensten Kriterien und Workflows gefiltert werden.

Gerätetypenerkennung												
+ Gerätetypen erkennen												
FILTER Von * 01.01.2024 Bis * 15.02.2024 Messpunktnummer Kategorie Tariftabellen Gruppe Workflows Level Gerätetypen Abweichung von Abweichung bis Installiert Erkannt - Alle - - Alle - X Wärmepumpe X % % Ja X Ja X Filter Zurücksetzen												
ID	Zeitstempel	Lastgangszeitraum	Messpunkt	Kategorie	Workflow	Nachricht	Gerätetyp	Gewissheit I	Installiert	Abweichung	Erkannt	Gewissheit E
544048	10.02.2024, 01:37:42	10.01.2024 – 10.02.2024	CH103420123450100000000000002761	Haushalt	HeatPump	DEBUG: Skipped	Wärmepumpe	Sicher Ja	10.880 kW	-23 %	8.369 kW	0.999
544156	10.02.2024, 01:38:03	10.01.2024 – 10.02.2024	CH103420123450100000000000002763	Haushalt	HeatPump	DEBUG: Skipped	Wärmepumpe	Sicher Ja	8.760 kW	-18 %	7.160 kW	0.991
544163	10.02.2024, 01:38:05	10.01.2024 – 10.02.2024	CH103420123450100000000000002792	Haushalt	HeatPump	DEBUG: Skipped	Wärmepumpe	Sicher Ja	8.280 kW	-13 %	7.218 kW	0.982
544247	10.02.2024, 01:38:17	10.01.2024 – 10.02.2024	CH103420123450100000000000002800	Haushalt	HeatPump	DEBUG: Skipped	Wärmepumpe	Sicher Ja	8.600 kW	-4 %	8.220 kW	1.000
544301	10.02.2024, 01:38:26	10.01.2024 – 10.02.2024	CH103420123450100000000000002416	Haushalt	HeatPump	DEBUG: Skipped	Wärmepumpe	Sicher Ja	9.760 kW	-26 %	7.213 kW	0.992
544364	10.02.2024, 01:38:35	10.01.2024 – 10.02.2024	CH103420123450100000000000002438	Haushalt	HeatPump	DEBUG: Skipped	Wärmepumpe	Sicher Ja	7.920 kW	8 %	8.584 kW	0.891

Abbildung 5: Analyse Auswertung Flexibilitäten (Beispiel Wärmepumpen)

Von den Technischen Betrieben Vilters-Wangs haben wir eine Messpunktliste sämtlicher bekannter Flexibilitäten erhalten. Siehe Abbildung 5: Analyse Auswertung Flexibilitäten (Beispiel Wärmepumpen) und Abbildung 6: Analyse Auswertung Flexibilitäten (Beispiel Batterien) Spalte Gewissheit: «Sicher Ja». Wird beim Detektions-Workflow eine Flexibilität erkannt, wird zusätzlich die aktuelle Leistungsaufnahme (Spalte Erkannt) ermittelt und die Abweichung in % zur gemeldeten Leistungsaufnahme (Spalte Abweichung) berechnet.



ID	Zeitstempel	Lastgangzeitraum	Messpunkt	Kategorie	Workflow	Nachricht	Gerätetyp	Gewissheit	Installiert	Abweichung	Erkannt
363793	07.10.2023, 01:56:36	07.09.2023 – 07.10.2023	CH1034201234501000000000000002554	Haushalt	Battery	INFO: Skipped	Batterie		✖		3.840 kW
364577	07.10.2023, 02:08:18	07.09.2023 – 07.10.2023	CH1034201234501000000000000001780	Industrie/Gewerbe	Battery	INFO: Skipped	Batterie		✖		26.630 kW
364727	07.10.2023, 02:10:22	07.09.2023 – 07.10.2023	CH1034201234501000000000000002523	Haushalt	Battery	INFO: Skipped	Batterie		✖		4.160 kW
365872	07.10.2023, 02:27:10	07.09.2023 – 07.10.2023	CH1034201234501000000000000002204	Haushalt	Battery	INFO: Skipped	Batterie	Sicher Ja	7.200 kW	47 %	3.828 kW
360647	30.09.2023, 04:25:46	30.08.2023 – 30.09.2023	CH1034201234501000000000000002051	Haushalt	Battery	INFO: Skipped	Batterie	Sicher Ja	5.500 kW	39 %	7.621 kW
361201	30.09.2023, 04:38:01	30.08.2023 – 30.09.2023	CH1034201234501000000000000001015	Haushalt	Battery	INFO: Skipped	Batterie	Sicher Ja	10.000 kW	27 %	7.324 kW
372204	07.10.2023, 04:36:14	07.09.2023 – 07.10.2023	CH1034201234501000000000000001511	Haushalt	Battery	INFO: Skipped	Batterie	Sicher Ja	6.000 kW	0 %	6.012 kW
372231	07.10.2023, 04:36:52	07.09.2023 – 07.10.2023	CH1034201234501000000000000001530	Haushalt	Battery	INFO: Skipped	Batterie	Sicher Ja	3.100 kW	4 %	3.232 kW
372405	07.10.2023, 04:40:49	07.09.2023 – 07.10.2023	CH1034201234501000000000000001917	Haushalt	Battery	INFO: Skipped	Batterie		✖		4.972 kW
372406	07.10.2023, 04:40:53	07.09.2023 – 07.10.2023	CH1034201234501000000000000001918	Haushalt	Battery	INFO: Skipped	Batterie	Sicher Ja	7.700 kW	35 %	5.033 kW
372435	07.10.2023, 04:41:28	07.09.2023 – 07.10.2023	CH1034201234501000000000000000881	Haushalt	Battery	INFO: Skipped	Batterie	Sicher Ja	7.500 kW	32 %	5.096 kW

Abbildung 6: Analyse Auswertung Flexibilitäten (Beispiel Batterien)

2.4 Disaggregation

Ein Lastgang lässt sich nach den verschiedensten, implementierten Modellen (Workflows) analysieren. Ein Workflow kann aus verschiedenen Stages (Teilaufgaben) bestehen.

Disaggregation bearbeiten

Messpunkt *

CH1034201234501000000000000002277

Workflow *

☐ WorkflowDisaggregationBoiler

☒ WorkflowDisaggregationChargingStation

☐ WorkflowDisaggregationHeatPump-giases-v1.5

☐ WorkflowDisaggregationPhotovoltaic

☐ WorkflowRemoveDisaggregationBoiler

☐ WorkflowRemoveDisaggregationChargingStation

☐ WorkflowRemoveDisaggregationHeatPump-giases-v1.5

☐ WorkflowRemoveDisaggregationPhotovoltaic

Diagrammtyp *

☒ Linie

☐ Säule

☐ Fläche

Speichern

Abbrechen

Abbildung 7: Auswahl der Disaggregations-Modelle




Abbildung 8: Wohnungs-Lastgang




Abbildung 9: Disaggregierte Ladestation (blaue Linie)

In der Abbildung 9: Disaggregierte Ladestation (blaue Linie) wurde der Ladestations-Lastgang aus dem Gesamtlastgang (rote Linie) extrahiert.

3 Vorgehen und Methode

Das Projektziel ist ein intelligentes Lastmanagement unter realen Bedingungen in einem Feldtest durchzuführen und zu erproben, indem die in Haushalten und Betrieben bereits vorhandenen verschiebbaren grossen Verbraucher automatisiert identifiziert und nutzbar gemacht werden. Dazu war es notwendig die für das Projekt bereitgestellten Netzabschnitte bzw. Messpunkte der beteiligten Verteilnetzbetreiber, EVUs und Stadtwerke in die System-Infrastruktur der ASGAL Informatik GmbH zu integrieren. Diese dienen als Datenbasis für das Training und die Validierung der Algorithmen. Die in den Vorarbeiten (Innosuisse-Projekt NILM4Bal [1]) entwickelten Algorithmen zur Erkennung und Disaggregation von Wärmepumpen und PV-Anlagen wurden optimiert und für die Erkennung und Analyse von Boilern sowie Elektro-Ladestationen weiterentwickelt. Die Algorithmen zur Vorhersage des Energiebedarfes von Wärmepumpen (inkl./exkl. Warmwassererwärmung) wurden ebenfalls weiterentwickelt sowie um neue Komponenten ergänzt. Für die Entwicklung und Erprobung des intelligenten Lastmanagements im Rahmen eines Feldtests mit Echtzeitdaten wurden die relevanten und hinter Messpunkten verborgenen (im Detail oft unbekannten) Prosumer auf den Ebenen von Ein- und Mehrfamilienhäusern, ZEVs, gewerblichen Gebäuden sowie Netzübergängen (Trafostationen Ebene 6) automatisiert identifiziert und disaggregiert sowie die Verbraucher auf ihr Lastverschiebepotential hin analysiert. Für die identifizierten PV-Anlagen wurde zudem die Produktion unter Zuhilfenahme von Wetterdaten (Sonneneinstrahlung und Temperatur) prognostiziert. Die Einzelheiten sind den folgenden Unterkapiteln zu entnehmen.

3.1 Inbetriebnahme Infrastruktur

Die Messpunkte der Netzabschnitte der beteiligten EVUs wurden in die Infrastruktur der ASGAL Informatik GmbH integriert. Individuell angepasst an das jeweilige EVU wurden gemäss dem entsprechenden Head End System (HES) und mittels Konvertierung in die notwendigen OBIS-Codes die Daten-Schnittstellen realisiert. Über die implementierten Schnittstellen wurden einerseits historische Messdaten der Jahre 2019 bis 2023 importiert und andererseits der Echtzeitdatenimport in Betrieb genommen.

Zur Erprobung des Systems wurde für das GIASES-Projekt ein eigenes webbasiertes Smart Energy System (SES) für die Visualisierung und Analyse der Messpunktdaten der beteiligten EVUs entwickelt und in Betrieb genommen (ausgenommen TB Vilters-Wangs, da als Bestandskunde bereits ein dediziertes SES für dieses EVU vorhanden ist).

Eine detaillierte Beschreibung des GIASES Smart Energy Systems (SES) kann Kapitel 2 Anlagenbeschrieb entnommen werden.

3.2 Aufbereitung der Messdaten

Die Aufbereitung der historischen Messdaten als Vorbereitungsschritt zum Trainieren der Algorithmen wurde über eine Pre-Processing-Pipeline implementiert. Dabei wurden folgende Schritte durchgeführt:

1. Evaluierung der Datenqualität und Bereinigung (Indexierung, Interpolation und Ersatzwertbildung)
2. Import der Daten in das nilmtk-Toolkit [2], [3] für einen standardisierten Zugriff auf die Datenbasis, was eine Selektion einzelner oder mehrerer Messpunkte bzw. Verbraucher in Kombination mit dem Gesamtsignals (site_meter) ermöglicht. Ausserdem kann dadurch eine flexible Auswahl der Zeitreihenbereiche sowie die Integration von Metadaten [4], [5] in einer standardisierten Form realisiert werden. Die so aufbereiteten Daten wurden im HDF5-Format [6] für den weiteren Datenaustausch abgespeichert. Das folgende Schaubild zeigt beispielhaft die Selektion für ein MFH des EVUs Vilters-Wangs.



```
{'instance': 13, 'original_name': '7323 Wangs MFH', 'dataset': 'GIASES'}
MeterGroup(meters=
  ElecMeter(instance=1, building=13, dataset='GIASES', site_meter, appliances=[])
  ElecMeter(instance=2, building=13, dataset='GIASES', appliances=[Appliance(type='apartment', instance=1)])
  ElecMeter(instance=3, building=13, dataset='GIASES', appliances=[Appliance(type='heat pump', instance=1)])
  ElecMeter(instance=4, building=13, dataset='GIASES', appliances=[Appliance(type='shared', instance=1)])
  ElecMeter(instance=5, building=13, dataset='GIASES', appliances=[Appliance(type='apartment', instance=2)])
  ElecMeter(instance=6, building=13, dataset='GIASES', appliances=[Appliance(type='apartment', instance=3)])
  ElecMeter(instance=7, building=13, dataset='GIASES', appliances=[Appliance(type='apartment', instance=4)])
  ElecMeter(instance=8, building=13, dataset='GIASES', appliances=[Appliance(type='apartment', instance=5)])
  ElecMeter(instance=9, building=13, dataset='GIASES', appliances=[Appliance(type='apartment', instance=6)])
  ElecMeter(instance=10, building=13, dataset='GIASES', appliances=[Appliance(type='apartment', instance=7)])
  ElecMeter(instance=11, building=13, dataset='GIASES', appliances=[Appliance(type='apartment', instance=8)])
  ElecMeter(instance=12, building=13, dataset='GIASES', appliances=[Appliance(type='apartment', instance=9)])
)
TimeFrame(start='2021-01-01 00:15:00+01:00', end='2022-01-01 00:00:00+01:00', empty=False)
```

Abbildung 10: Beispiel Datenselektion für ein MFH mittels nilmtk-Toolkit

- Import der nilmtk-Daten (hdf5) in die Entwicklungsumgebung und Aufbereitung der Daten in Input und Labels (Ground Truth).
- Aufteilung in Trainings-, Validierungs- und Testdatensätze.

3.3 Gerätetyperkennung

Für die Erkennung von **Wärmepumpen** und **PVA** wurden die Algorithmen aus den Vorarbeiten (NILM4Bal Innosuisse-Projekt) zur Verwendung im GIASES-Projekt adaptiert und optimiert.

Für die Erkennung des Gerätetyps **Boiler** wurde ein neuer Algorithmus (SpikeDetection) entwickelt, der über verschiedene Features wie Schwellenwerte und Aktivitätsmuster die Charakteristiken von Boiler-Ladekurven identifiziert. Zusätzlich liefert der Algorithmus Metadaten, wie Ein- und Ausschaltzeitpunkte bzw. Dauer und Maximalleistung.

	A	D	E	F	G	H	I	J	K
1	Messpunkt-ID	Analysedaten von	Analysedaten bis	Gerät	Geräteleistung	Gewissheit	Einschaltzeitpunkt	24-Tage-Block mit den m	Durchschnittliche
2	1956	01.10.2021 00:00	01.04.2022 00:00	Boiler	3307 W	100.00%	23:30:00	[02.10.2021 - 25.10.2021]	322 min
3	1957	01.10.2021 00:00	01.04.2022 00:00	Boiler	3768 W	73.91%	23:30:00	[02.10.2021 - 25.10.2021]	316 min
4	2441	01.10.2021 00:00	01.04.2022 00:00	Boiler	5306 W	100.00%	22:15:00	[03.12.2021 - 26.12.2021]	303 min
5	1924	01.10.2021 00:00	01.04.2022 00:00	Boiler	3563 W	72.73%	22:30:00	[19.11.2021 - 12.12.2021]	298 min
6	3016	01.10.2021 00:00	01.04.2022 00:00	Boiler	12792 W	100.00%	23:15:00	[02.10.2021 - 25.10.2021]	266 min
7	1955	01.10.2021 00:00	01.04.2022 00:00	Boiler	5182 W	100.00%	22:30:00	[19.11.2021 - 12.12.2021]	242 min
8	2437	01.10.2021 00:00	01.04.2022 00:00	Boiler	9527 W	100.00%	22:15:00	[03.12.2021 - 26.12.2021]	237 min
9	3384	01.10.2021 00:00	01.04.2022 00:00	Boiler	3965 W	100.00%	02:15:00	[13.12.2021 - 05.01.2022]	231 min
10	1950	01.10.2021 00:00	01.04.2022 00:00	Boiler	6969 W	95.65%	22:15:00	[06.01.2022 - 29.01.2022]	229 min
11	3419	01.10.2021 00:00	01.04.2022 00:00	Boiler	3461 W	78.26%	22:30:00	[30.01.2022 - 22.02.2022]	227 min
12	1903	01.10.2021 00:00	01.04.2022 00:00	Boiler	16414 W	100.00%	22:15:00	[06.01.2022 - 29.01.2022]	221 min
13	2252	01.10.2021 00:00	01.04.2022 00:00	Boiler	6009 W	82.61%	23:15:00	[03.12.2021 - 26.12.2021]	219 min
14	2975	01.10.2021 00:00	01.04.2022 00:00	Boiler	3268 W	95.65%	22:15:00	[19.11.2021 - 12.12.2021]	216 min
15	3222	01.10.2021 00:00	01.04.2022 00:00	Boiler	10621 W	100.00%	22:15:00	[13.12.2021 - 05.01.2022]	211 min
16	3378	01.10.2021 00:00	01.04.2022 00:00	Boiler	3063 W	83.33%	22:30:00	[23.02.2022 - 18.03.2022]	205 min
17	2951	01.10.2021 00:00	01.04.2022 00:00	Boiler	3854 W	100.00%	23:30:00	[02.10.2021 - 25.10.2021]	202 min
18	2932	01.10.2021 00:00	01.04.2022 00:00	Boiler	9925 W	91.30%	02:45:00	[02.10.2021 - 25.10.2021]	201 min
19	2088	01.10.2021 00:00	01.04.2022 00:00	Boiler	3297 W	73.91%	22:15:00	[07.03.2022 - 30.03.2022]	200 min
20	2971	01.10.2021 00:00	01.04.2022 00:00	Boiler	2382 W	91.30%	23:15:00	[02.10.2021 - 25.10.2021]	199 min
21	1958	01.10.2021 00:00	01.04.2022 00:00	Boiler	4124 W	86.36%	22:15:00	[13.12.2021 - 05.01.2022]	192 min

Abbildung 11 Gruppierung von Boilern nach den detektierten Metadaten (Beispiel: Durchschnittliche Ladezeit)

Für die Erkennung von **E-Ladestationen** wurde ebenfalls ein neuer Algorithmus entwickelt, der auf einem ähnlichen Ansatz basiert, wie bei der Gerätetyperkennung Boiler.

Bei **Batterien** im Zusammenhang mit einer PVA wurde ebenfalls ein neuer Algorithmus entwickelt.

3.4 Disaggregation / Lastgangerkennung

Wärmepumpe

Zuerst wurde die Entwicklungsumgebung für die Implementierung und Dokumentation der Disaggregations-Algorithmen aufgesetzt. Die Experimente wurden in Jupyter-Notebooks [7] durchgeführt. Für die Dokumentation und Nachvollziehbarkeit der Experimente wurde ein MLFlow-Server [8] aufgesetzt und die Schnittstellen in die Entwicklungsumgebung integriert. Als ML-Framework wurde die tf.keras API von TensorFlow [9] verwendet.

Der Algorithmus basiert auf der bereits im NILM4Bal verwendeten WAVENILM-Architektur [10], die mit den über nilmtk importierten Daten (siehe Kapitel 3.2) des GIASES-Projektes trainiert, optimiert und evaluiert wurde. Als Datenbasis dienten 13 Mehrfamilienhäuser, die mit gemessenen Wärmepumpendaten (Ground Truth) ausgestattet sind. Die verwendeten Daten umfassten das komplette Jahr 2021 mit einer Auflösung von 15 Minuten. Die Länge der Sequenz wurde auf 96 Datenpunkte (1 Tag) festgelegt. Somit standen für die Entwicklung des Algorithmus insgesamt 4745 Samples mit jeweils 96 Datenpunkten zur Verfügung.

Für die Erfolgskontrolle wurde mittels einer 7-fold-cross-validation 7 einzelne Modelle mit jeweils 11 unterschiedlichen MFH trainiert und mit 2 MFH getestet, die nicht im Trainingssatz enthalten und somit dem Algorithmus nicht bekannt waren. Abbildung 48 im Anhang zeigt die Werte der Metriken für die einzelnen Folds sowie am Ende den repräsentativen Durchschnitt über alle Folds gemittelt.

Im Folgenden werden die zur Erfolgskontrolle verwendeten Metriken im Einzelnen erläutert:

total_energy_error (kWh)

Ist die Summe der Abweichungen zwischen Disaggregation und Ground Truth umgerechnet in Energie. Der Error kann sich über die Samplelänge ausgleichen, wenn teils über- und teils unterschätzt wird. Wenn insgesamt mehr unterschätzt wird kann der Wert auch negativ werden.

```
def total_energy_error(y_true, y_pred):  
    """  
    Calculate the total consumed energy error in kWh per sample  
    """  
    # Divide by 4 since we sample in 15 minute intervalls  
    energy_true = y_true / 4.0  
    energy_pred = y_pred / 4.0  
    return K.sum(energy_pred - energy_true)
```

rel_total_energy_error

Wie oben, aber als relativer Wert normiert um die Ground Truth.

```
def rel_total_energy_error(y_true, y_pred):  
    """  
    Calculate the relative consumed energy error per sample  
    """  
    # Divide by 4 since we sample in 15 minute intervalls  
    energy_true = y_true / 4.0  
    energy_pred = y_pred / 4.0  
    return K.sum(energy_pred - energy_true) / K.sum(energy_true)
```

abs_total_energy_error (kWh)

Gibt an, wie gross die durchschnittliche Abweichung der einzelnen, geschätzten Momentanwerten von den gemessenen Momentanwerten (Ground Truth) ist. Sie ist das Mass für die Treffsicherheit der Algorithmen in Bezug auf den Verlauf der Kurven (wie gut liegen die realen und generierten Kurven übereinander). Zu beachten ist, dass der total_energy_error im Regelfall niedriger ist als der abs_total_energy_error, da sich beim total_energy_error positive und negative Fehler gegenseitig kompensieren können.



```
def abs_total_energy_error(y_true, y_pred):  
    """  
    Calculate the abs total consumed energy error in kWh per sample  
    """  
    # Divide by 4 since we sample in 15 minute intervalls  
    energy_true = y_true / 4.0  
    energy_pred = y_pred / 4.0  
    return K.sum(K.abs(energy_pred - energy_true))
```

rel_abs_total_energy_error

Wie oben, aber als relativer Wert normiert um die Ground Truth.

```
def rel_abs_total_energy_error(y_true, y_pred):  
    """  
    Calculate the relative abs total consumed energy error (RATEE) per sample  
    """  
    # Divide by 4 since we sample in 15 minute intervalls  
    energy_true = y_true / 4.0  
    energy_pred = y_pred / 4.0  
    ratee = K.sum(K.abs(energy_pred - energy_true)) / K.sum(energy_true)  
    return ratee
```


total_energy_gt (kWh)




Gesamtenergie der Ground Truth.

mean_absolute_error (kW)

Durchschnittliche Abweichung der Leistung der einzelnen Messpunkte.

Die folgenden Plots zeigen jeweils ein exemplarisches Ergebnis eines Tages für jeden Fold:








Abbildung 12: Einzelplots Disaggregation Wärmepumpe

PVA




Abbildung 13: Input-Lastgang (rot), PV- Disaggregation (dunkelgrün)

Die Disaggregation von PV-Anlagen in Kombination mit bekannten PVA-Referenzanlagen wurde in einem eigenen Stage realisiert. Die folgende Abbildung zeigt in einem Beispiel eine Gegenüberstellung der PV-Disaggregation mit der entsprechenden Ground Truth.




Abbildung 14: Ground Truth (hellgrün), PV-Disaggregation (dunkelgrün)

Dieser Ansatz liefert bei Boiler, die regelmässig zur selben Zeit aktiv sind, gute Resultate. Gleichzeitig kann mit dieser Methode die Dauer jedes Boiler-Peaks durch die Leistungsdifferenz des Peaks und des regulären Verbrauchs berechnet werden.

E-Ladestationen




Abbildung 16: Lastgang E-Ladestation

Auch die Disaggregation von E-Ladestationen bauen auf demselben Anomalie-Detektor wie beim Boiler-Algorithmus auf. Hier wird geprüft, ob die Grösse der Peaks ungefähr mit den bekannten Ladestationen-Standards übereinstimmt.

Meta-Informationen einer Batterie




Abbildung 17 EFH mit Batterie, PVA und Wärmepumpe

Die direkte Disaggregation eines Lastgangs einer Batterie ist mit den vorhandenen Daten nicht möglich, jedoch lassen sich wichtige Metainformationen generieren. Bei Gebäuden mit einer PV-Produktion (grüne Linie in Abbildung 17) und dem entsprechenden Netzübergabe-Lastgang (blaue Linie in Abbildung 17) kann die Batterie Lade- / Entlade-Zeit, maximale Ladeleistung und Speichermenge bestimmt werden. In der Zeitspanne, wo der Netzübergabepunkt keine Energie bezieht oder abgibt, kann keine Aussage über den internen Verbrauch gemacht werden. In dieser Zeit können die vorhandenen Flexibilität nicht disaggregiert werden. In den Sommer-Monaten wird an sonnigen Tagen keine Energie vom Verteilnetzbetreiber bezogen und zwischen 11 – 18 Uhr Energie zurück gespiesen. Im Winter erfolgt die Rückspeisung im Zeitraum von 12 – 16 Uhr. Für die Verteilnetzbetreiber sind die installierten Batterien während den Winter-Monaten sehr netzdienlich. Im Lastspitzen-Zeitbereich von 17 – 21 Uhr wird keine Energie bezogen.

3.5 Vorhersage von Verbrauchsspuren

Vorhersagekonzept und optimierte Verbrauchsplanung:

Die von Smart-Metern gemessene Gesamtenergie der Messpunkte wurde für die Vorhersage in drei Teile aufgeteilt. Die Teile bestehen aus Raumwärme (Heizung resp. Wärmepumpe), Warmwasser (Boiler) und Rest-Verbrauch (Smart-Meter abzüglich Wärmepumpe und Warmwasser). Für jeden dieser Anteile, d.h. für jede Komponente, wurde ein angepasstes Verfahren entwickelt, welches ermöglicht, aus den disaggregierten Verbräuchen sowohl die einzelnen Teile als solche, wie auch durch Addition der gewonnenen Komponentenresultate den Gesamtenergieverbrauch vorherzusagen. Das gesamte Vorhersageframework ist so aufgebaut, dass weitere Komponenten, wie zum Beispiel E-Ladestationen, in Zukunft sehr einfach hinzugefügt werden können. Über definierte Schnittstellen sind die entwickelten Algorithmen ins GIASES Smart Energy System integriert.

Für die optimierte Verbrauchsplanung wurde ein Test-Fall definiert, bestehend aus einer Mischung von elektrischen Verbrauchsdaten von Gebäuden mit und ohne Wärmepumpen. Damit wurde ein Optimierungsverfahren entwickelt, welches vorhergesagte Lastspitzen selbständig erkennt und versucht diese zu minimieren. Als Resultat wird eine Steuerstrategie für die enthaltenen flexiblen Komponenten vorgeschlagen und gemeinsam mit einer angepassten Vorhersage zurückgegeben. Über eine definierte Schnittstelle ist die Lastverschiebe-Optimierung ins GIASES Smart Energy System integriert.

Eine Übersicht der Ergebnisse aller Vorhersagemethoden sowie der optimierten Verbrauchsplanung findet sich in Abschnitt 4.4.

Komponentenweise Beschreibung der Vorhersage-Methodik: Wärmepumpen, Boiler und Rest-Verbrauch

Für die Vorhersage der Komponente Wärmepumpe wurde ein Algorithmus basierend auf dem aggregierten Energieverbrauch von mehreren Wärmepumpen entwickelt. Die aggregierten Daten wurden als Basis gewählt, da es sich einerseits um einen der häufigsten Anwendungsfälle handelt, sich andererseits ausgleichende statistische Effekte ausnutzen lassen. Basierend auf diesen Wärmepumpenverbrauchsdaten wurde eine Vorhersagemethode entwickelt, welche mithilfe von historischen Verbrauchsdaten, entsprechender Wetterinformation und Vorhersage, die notwendige Energie für den Wärmebedarf wählbarer Zeitbereichen (üblicherweise 24h Profil) abschätzen kann. Die entwickelte Methode besteht aus der Vereinigung eines statistischen Ansatzes und einer simplen physikalischen Modellierung. Der statistische Teil besteht aus der Bildung eines mittleren Tages-Profils. Damit können Profil-Eigenheiten spezifischer Systeme, wie zum Beispiel vermehrter Einsatz zu Niedertarifzeiten, erkannt und in die Vorhersage integriert werden. Um die Temperaturabhängigkeit des Wärmebedarfs in der Vorhersage abbilden zu können, werden im physikalischen Teil die Heizgradstunden verwendet. Die Temperatur-Differenz zwischen einer festgelegten Heizgrenze (14°C) wird stündlich erfasst und aufsummiert. Ein Gebäude-spezifischer Skalierungsfaktor wird so berechnet, dass der aufsummierte Wert mit dem totalen Verbrauch der Wärmepumpe über bestimmte Zeiten möglichst gut übereinstimmt. Der Skalierungsfaktor zusammen mit einer Temperaturvorhersage erlaubt so eine temperaturabhängige Vorhersage des Energieverbrauchs. Beide Teile, statistisch und physikalisch, können dann gewichtet zusammengefügt werden. Eine selbst-optimierende, dynamische Gewichtung der beiden Teile in der Zusammenfügung ist Gegenstand weiterer Forschung.

Hinsichtlich des Energieverbrauchs zur Warmwasseraufbereitung konnte mithilfe eines Datensets bestehend aus disaggregierten Boiler-Verbrauchsdaten ein Vorhersagemodell entwickelt und getestet werden. Da Boiler-Verbrauchsdaten üblicherweise eine sehr hohe Regelmässigkeit und keine ausgeprägte Temperaturabhängigkeit aufweisen, wurde ein Gebäude-spezifisches, über die Trainingsdaten gemitteltes, Referenzprofil zur Vorhersage verwendet. Dies ist die in Abschnitt 4.4 validierte Version. Zusätzlich wurden potenzielle Optimierungen identifiziert, welche in zukünftigen Projekten getestet werden können. Rein statistisch lässt sich vermutlich eine Verbesserung durch separate Referenzprofil-Berechnungen abhängig von Wochen-/Ferien-/Kalendertagen erzielen. Zusätzlich können Wahrscheinlichkeitsanalysen für Nachheizzeitpunkte Muster liefern, die

benutzerspezifische Bezüge berücksichtigen können. Als zusätzlicher Modellierungsschritt können die Auflade-Zyklen mit Zapfprofilen verglichen werden, um so eine genauere Abschätzung über die Dauer der Auflade-Zyklen oder das Eintreten von Nachladungen zu erhalten.

Die dritte Komponente des entwickelten Modells für die Gesamtenergievorhersage bildet der übrige Verbrauch. Die Resultate der Disaggregation erlauben eine separate Betrachtung des Rest-Verbrauchs der einzelnen Messpunkte, also ohne Wärmepumpe und Warmwasseraufbereitung. Mithilfe dieser historischen Profile kann ein aus den Trainingsdaten gemittelt Referenz-Profil erstellt und zur Vorhersage genutzt werden. Aufgrund der unbekannten Zusammensetzung der Komponenten im Rest-Verbrauchs wurde auf die Entwicklung von komplexeren Algorithmen verzichtet.

3.6 Flexibilitätslabel / Haustyperkennung

Es wurde eine Flexibilitätsmatrix eingeführt, welche das Flexibilitätspotential von Gebäuden beschreibt und vergleichbar macht. Durch einen hierarchischen resp. modularen Aufbau wird berücksichtigt, dass nicht überall detaillierte Informationen zu den Objekten und vorhandenen Komponenten verfügbar sind. In einem ersten Schritt werden öffentlich zugängliche Daten verwendet (z.B. aus dem Gebäude- und Wohnungsregister GWR) sowie der Komponentennachweis durch das GIASES Smart Energy System. In den weiteren Schritten werden historische Lastgänge verwendet sowie detaillierte Komponenteninformationen wie beispielsweise Unterschiede des Verbrauchs an Wochentagen und an Wochenenden. Der letzte Schritt wird in diesem Projekt nicht ausgearbeitet, wir stellen ihn jedoch als Ausblick vor. Als weiteres Modul können die Vorhersagen verwendet werden, um die Flexibilitätsmatrix für den Vorhersagetag zu bestimmen.

Die Flexibilitätsmatrix beinhaltet Antworten zu den Flexibilitätseigenschaften Wann? (Monatliche und stündliche Verfügbarkeit), Wie viel? (Amplituden), Wie lange? (Dauer), Wie lange bis erneut nutzbar? (Recovery). In einem ersten Bewertungsszenario lag der Fokus auf den Komponenten Wärmepumpe, Boiler und Elektroauto. Mit dieser Flexibilitätsmatrix und dem eingeführten Verfahren lassen sich jedoch sehr einfach weitere Komponenten abbilden und aufgrund des additiven Charakters des Flexibilitätspotentials in der Gesamtbewertung berücksichtigen. Die Bewertungen des nutzbaren Potenzials kann durch unterschiedliche Abfragen an die Flexibilitätsmatrix für verschiedene Anwendungsfälle unterschiedlich ausfallen. Der so entstandene Flexibilitäts-Score widerspiegelt dann nicht lediglich eine allgemeine Eigenschaft eines Gebäudes oder einer einzelnen Komponente, sondern gibt eine Antwort auf ein spezifisches Szenario (siehe Abschnitt 4.5 für ein praktisches Fallbeispiel).

3.7 Lastverschiebung / Ansteuerung

Der Boiler-Workflow wurde um einen Stage erweitert, der zusätzliche Metadaten wie Leistungsaufnahme, Einschaltzeitpunkt, Anzahl Schaltzyklen, durchschnittliche Einschaltzeit, maximale Einschaltzeit pro Boiler-Messpunkt eruiert. Basierend auf den Erkenntnissen der Boiler-Disaggregation und den aufgezeichneten Metadaten (Leistungsaufnahme und mittlere Einschaltdauer) können die Rundsteuer-Boiler-Gruppen gezielt nach der mittleren Einschaltdauer neu gruppiert werden. Die Umgruppierung ermöglicht die Verschiebung von Boiler-Gruppen in den Niedrig-Lastbereich von 2 – 5 Uhr. In Kapitel 4.7 ist ein Beispiel für eine Ladezeit optimierte Umgruppierung von Boilern aufgeführt, die im Rahmen des Feldtests erarbeitet wurde. Diese Massnahme wird auch einen positiven Effekt auf die Energieeinkaufskosten zu Tiefpreiszeiten haben.




Abbildung 18: Ladestationen, Hauptladezeiten von privaten E-Fahrzeugen

Die Disaggregation der Ladestationen-Messpunkte hat ergeben, dass die meisten Ladevorgänge werktags zwischen 17 und 23 Uhr mit einer mittleren Ladezeit von 2 Stunden erfolgen. Die Hauptladezeit von E-Fahrzeugen überschneidet sich genau mit den heutigen Lastspitzenmaximum von 18 bis 21 Uhr. Aktuell fehlen in den Werkvorschriften Bestimmungen dies zu unterbinden. Mit einem Flexibilitätsmodell, dass Kunden belohnt, die nicht zwischen 17 und 23 Uhr laden, könnte ein wichtiger Beitrag zur Lastspitzenreduktion in den Abendstunden erfolgen.

Einen sehr positiven Effekt zur Lastspitzenreduktion von 18 bis 21 Uhr haben die im privaten Bereich eingesetzten Batterien. Leider wird die installierte Speicherkapazität auch in absehbarer Zukunft viel zu gering sein, um einen spürbaren Lastspitzen-Reduktionsbeitrag zu leisten. Mit einem Flexibilitätsmodell könnten die Besitzer der Batterien motiviert werden ihre Batterie dem EVU für Systemdienstleistungen zur Verfügung zu stellen.

Die Summierung der disaggregierten Wärmepumpen Lastgänge zeigt auf, dass in den Wintermonaten (Dezember bis Februar) während den Verbrauchsspitzenzeiten (18 bis 21 Uhr) die Wärmepumpen einen immer stärkeren Einfluss auf die Lastspitze haben. Bei Temperaturen unter 0 Grad ist ein grosser Teil der Wärmepumpen über längere Zeit im Einsatz.

Die Ansteuerung der Wärmepumpen via dem Smart Grid Ready Signal hat sich als schwieriger als geplant herausgestellt. Aktuell ist es noch nicht möglich, dass die verschiedenen Wärmepumpen Hersteller einfach angesteuert werden können. Für den externen Zugriff auf die Wärmepumpen fehlen auch bei neueren Gebäuden oft die Kommunikationsanbindungen (siehe auch Kapitel 7.1). Hier wäre es hilfreich, wenn es international abgestimmte Vorgaben geben würde. Mit einzelnen Wärmepumpen erfolgen Versuche zur Überprüfung der Konzepte.

4 Ergebnisse und Diskussion

4.1 Inbetriebnahme Infrastruktur / Aufbereitung der Messdaten

Die folgende Abbildung zeigt eine Ergebnisübersicht, der von den einzelnen EVUs für das Projekt integrierten Messpunkte:

	WP	Boiler	PVA	Batterie	Lade-station	Trafo-station	Mess-punkte
TB Vilters-Wangs	346	244	194	39	43	19	2890
EWA-energieUri	622	336	241		36	-	2429
CKW	55	8	17		1	1	216
WWZ		22					300
IBC	3		5			1	27
Total	1026	610	457	39	80	21	

Abbildung 19: Mengengerüst der Messpunkte

4.2 Feldtest

Nach der Inbetriebnahme der Infrastruktur und der Integration der Messpunkte konnte der Feldtest Anfang Q2/2022 mit Echtzeitdaten gestartet werden. Nach und nach wurden die Algorithmen zur Gerätetyperkennung, Disaggregation und Vorhersage in die Infrastruktur integriert und via SES-Portal validiert.

In den folgenden Kapiteln 4.3 bis 4.9 werden die Ergebnisse gewürdigt, die im Rahmen des Feldtests, gekoppelt mit Simulationen und deren Validierung, gewonnen wurden.

Im Einzelnen umfasst dies die Validierung der Gerätetyperkennung (Identifikation), der Disaggregation, der Vorhersage, der Haustyperkennung bzw. des Flexibilitätslabels sowie der Lastverschiebung. Neben den Flexibilitäten PVA, Wärmepumpe, Boiler und E-Ladestationen wurden im Laufe des Projekts zudem Batteriespeicher mit in den Fokus des Projektes aufgenommen, da im Verlauf der Validierung im Feldtest ersichtlich wurde, dass auch für Batteriespeicher eine Identifikation und Disaggregation möglich erscheint und somit zusätzliches Potential für die Informationsgewinnung über Flexibilitäten besteht.

Ausserdem wurden die Informationen von installierten Anlagen aus Anschlussgesuchen mit den anhand der Algorithmen gewonnenen Informationen verglichen und analysiert, inwieweit die Algorithmen zusätzliche Kenntnisse über den Anlagebestand liefern bzw. die Informationen der Anschlussgesuche ergänzen. Des Weiteren wurde eine vergleichende Analyse zwischen dem Vorgehen gemäss Netzplanungsgrundsätzen und gemäss Algorithmen erstellt sowie das generische Einsparpotential untersucht.

4.3 Gerätetyperkennung

Bei Ein- und Mehrfamilienhäusern können Photovoltaikanlagen unabhängig von der Anlagengrösse erkannt werden. Bei Gewerbe- und Industriemesspunkten mit einer zum Verbrauch verhältnismässig geringen PVA (keine Rückspeisung von Energie) kann eine PV-Anlage aktuell nicht erkannt werden.

Die Erkennung von Wärmepumpen, basierend auf dem adaptierten Algorithmus aus dem Vorgängerprojekt, funktioniert zuverlässig und liefert überwiegend sehr gute Ergebnisse. Abbildung 20 zeigt die Auswertung von etwas mehr als 8'000 Testbeispielen, die aufzeigt, dass nur ein geringer Anteil von Wärmepumpen falsch klassifiziert wurden (52 False Positive / 62 False Negative).




Abbildung 20: Confusion Matrix Gerätetyperkennung Wärmepumpe

Während den Sommer Monaten verhält sich eine Wärmepumpe, die rein für die Warmwasseraufbereitung läuft, wie ein Boiler. Somit wird der Sommer-Lastgang einer Wärmepumpe auch als Boiler erkannt.

Für die Erkennung der Gerätetypen Boiler und E-Ladestationen wurden neue Algorithmen entwickelt, welche anhand der jeweiligen relevanten Features die Charakteristiken der Ladekurven erkennt und den entsprechenden Gerätetyp klassifiziert.

Bei Mehrfamilienhäusern mit Wärmepumpen und einem Leistungsbereich von 7 kW - 12 kW kann es vorkommen, dass in den Sommermonaten die Wärmepumpe auch als Ladestation erkannt wird. Sind auch Messdaten von den Wintermonaten vorhanden, konnte die inkorrekte-Erkennung reduziert werden

Für die Gerätetyperkennung von Batterien wurde ein eigener Service implementiert. Der Service detektiert die folgenden Batterie Merkmale:

- Maximale Lade-Leistung
- Kapazität der Batterie
- Zeitbereich ohne Netzbezug

4.4 Disaggregation / Lastgangerkennung

Photovoltaikanlage (PVA)

Anhand von ausgewählten Referenzanlagen kann der entsprechende Produktionslastgang der PVA disaggregiert werden. Für die nachfolgenden Prozesse können reine Verbrauchslastgänge zur Verfügung gestellt werden. Die Feldversuche haben ergeben, dass die Qualität der Disaggregation der Flexibilität (Wärmepumpen, Boiler, Ladestationen, Batterien) markant verbessert werden kann, wenn zuvor die PV-Produktion aus dem zu analysierenden Lastgang entfernt wird.

Wärmepumpe




Abbildung 21 MFH Ground-Truth Lastgang (gelb) und Disaggregation (braun) des MFH-Netzübergabe Lastganges

Die Disaggregation mit dem entwickelten Algorithmus erzielt für MFH zufriedenstellende Ergebnisse. Die Abweichungen der Disaggregation zum Ground-Truth sind in der Abbildung 21 rot markiert.

Die Testergebnisse der 7-fold cross validation von 13 MFH über einen Zeitraum von einem kompletten Jahr (Abbildung 48) zeigen eine Abweichung der disaggregierten Gesamtenergie (TEST RESULTS MEAN FOR ALL FOLDS) von etwa 2 Prozent Unterschätzung ($\text{rel_total_energy_error} = -0.0203$) gegenüber der Ground Truth, was als sehr gut bezeichnet werden kann. Das Mass für die Treffsicherheit der Algorithmen in Bezug auf den Verlauf der Kurven (wie gut liegen die realen und generierten Kurven übereinander) zeigt hingegen eine Abweichung von etwa 33 Prozent ($\text{rel_abs_total_energy_error} = 0.3359$). Die exemplarischen Beispiele von Einzelplots (Abbildung 12) zeigen, dass diese Abweichungen im Verlauf der Kurven jedoch vorwiegend durch eine Über- oder Unterschätzung der einzelnen Peaks in den Lastkurven zustande kommen, die Peaks an sich aber recht zuverlässig erkannt werden können. Zudem gleichen sich die Über- und Unterschätzungen bei der Aggregation von mehreren Wärmepumpen in Summe annähernd aus, was die oben genannten 2 Prozent Abweichung bei der Gesamtenergie aufzeigt. Insgesamt bieten diese Ergebnisse somit eine nützliche und brauchbare Basis für ein erfolgreiches Lastmanagement, bei dem die Detektion der Peaks eine entscheidende Rolle spielt und die Abweichungen in den Spitzen zumindest teilweise durch die Aggregation der Flexibilitäten kompensiert werden.

Trotzdem bietet die Disaggregation weiterhin Potential für Verbesserungen, insbesondere die visuelle Validierung bei EFH hat gezeigt, dass das mit Daten von MFH trainierte Modell bei der Disaggregation von Wärmepumpen in EFH nicht immer zufriedenstellende Ergebnisse liefert. Da für EFH keine Ground Truth vorhanden ist (Wärmepumpen in EFH werden i.d.R. nicht separat gemessen) wurden im weiteren Verlauf des Feldtests weitere Möglichkeiten zur Optimierung des Algorithmus untersucht, wie Peak Classification und Rule-based Heuristics.

Boiler

Boiler können mithilfe des neu entwickelten Algorithmus disaggregiert werden. In Einzelfällen werden Boiler-Aktivierungen mit Überlagerungen von anderen Verbrauchern (z.B. Tumbler, Waschmaschine etc.) verwechselt, was zu einer Nichterkennung von einzelnen Peaks führen kann. Die Optimierung der Algorithmen ist ein fortlaufender Prozess, da die Disaggregations-Modelle mit den sich ständig verändernden Datenbeständen zyklisch durch erneutes Training aktualisiert werden müssen. Dies ist auch Bestandteil des Nachfolgeprojekts EkoFlex (siehe Kapitel 6).

Ladestationen

Bei Einfamilienhäusern können Ladestationen disaggregiert werden. Auch hier kommt es zu einzelnen Nichterkennungen von Ladezyklen, insbesondere bei niedrigen Ladeleistungen (≤ 3.6 kW). Die weitere Optimierung der Algorithmen ist ebenfalls Bestandteil des Nachfolgeprojekts. Tiefgaragen von Mehrfamilienhäusern müssen Ladestationen mit einem Lastmanagement (> 2 Wallboxen) einbauen. Hier ist die Datenlage noch zu gering, dass eine konkrete Aussage möglich wäre.

Batterien

Für die Disaggregation eines Batterie-Lastgangs fehlen die Messdaten im Lade- und Entlade-Zeitbereich (rote Rechtecke in Abbildung 22). Das Energiemanagement der Batterie regelt den Output dahingehen, dass weder Bezug noch die Rückgabe von Energie erfolgt.




Abbildung 22 EFH mit einer Batterie, PVA und Wärmepumpe

4.5 Vorhersage

Validierung der Komponentenvorhersage:

Zur Validierung wurde ein umfangreicher Datensatz aus Ground-Truth-Daten-Spuren von 18 Mehrfamilienhäusern (MFH) über 4 Jahre zusammengestellt, um eine ganzheitliche Analyse der Komponenten Wärmepumpen, Boiler und Rest-Verbrauch zu ermöglichen. Im Folgenden wird eine detailliertere Betrachtung dieser Komponenten einzeln vorgenommen. Die Validierung umfasste Daten aus dem Zeitraum von Januar 2019 bis März 2023, spezifisch für die Monate November bis März jedes Jahres. Während dieser Zeitspanne wurde für das Winterhalbjahr eine systematische Vorhersage und Analyse durchgeführt, indem jeder dritte Tag prognostiziert und evaluiert wurde. Dieses Vorgehen zielte darauf ab, eine repräsentative Sammlung verschiedener Wetterbedingungen und Wochentage zu erfassen.

Wärmepumpe:

Im Falle der Wärmepumpenkomponente ging der Validierung eine Modellparameteroptimierung voraus. Diese Modellparameter wurden für die tatsächliche Validierung fixiert.

Eine exemplarische Auswertung der Wärmepumpendaten eines einzelnen Tages ist in Abbildung 23 dargestellt. Die Abbildung zeigt die Daten eines siebentägigen Trainingszeitraums sowie die entsprechende Vorhersage (dargestellt in Blau) und die Ground-Truth-Daten (dargestellt in Rot) über einen 24-Stunden-Zeitraum einer Wärmepumpenspur. Bei der Vorhersage werden die historischen Verbräuche (grün) sowie die Aussentemperatur (violett, orange) mittels eines physikalischen Modells berücksichtigt.




Abbildung 23: Beispielauswertung der Vorhersage einer Wärmepumpe für einen Tag.

Abbildung 24 präsentiert die normierten Wurzeln der mittleren quadratischen Abweichungen (NRMSE) für einzelne Mehrfamilienhäuser (MFH), sortiert in aufsteigender Reihenfolge. Dabei wurde der RMSE der stündlichen Abweichungen für die WP-Komponente mit dem Mittelwert der Ground Truth Daten des Vorhersagetages normalisiert. Neben den individuellen Profilen der MFH wurde ein aggregiertes Profil erstellt (*agg_MFHs*) und ein Mittelwert über alle betrachteten MFH berechnet (*mean_MFHs*). Für das aggregierte Profil wurden die Bedarfsprofile aller MFH einzeln summiert und anschliessend analysiert. Die deutlich besseren Ergebnisse im aggregierten Fall lassen sich auf ausgleichende statistische Effekte zurückführen.

Als beurteilende Metrik wurde der NRMSE gewählt. Einerseits ermöglicht die Normierung Vorhersagen zu vergleichen unabhängig von den nominellen Leistungen der Wärmepumpen, andererseits sind Vorhersagen mit grosser Abweichung zu den echten Werten stärker zu gewichten, da diese insbesondere vermieden werden sollen. Die so berechnete Bewertung lässt sich als Schätzung für zukünftige Prognosegenauigkeiten wie folgt benutzen: In einem Ensemble von zukünftigen Vorhersagen kann die Standardabweichung der Fehlerverteilung durch Multiplikation des NRMSE und der durchschnittlich auftretenden Leistung abgeschätzt werden.




Abbildung 24: NRMSE Werte der Wärmepumpen Komponente für individuelle MFH, ein aggregiertes Profil (*agg_MFHs*) sowie einen Mittelwert über alle MFH (*mean_MFHs*), dargestellt in einer aufsteigenden Reihenfolge.

Abbildung 25 illustriert, wie der NRMSE mit zunehmender durchschnittlicher Tagestemperatur am Vorhersagetag ansteigt, was eine Verschlechterung der Vorhersagegenauigkeit signalisiert. Die Abbildung präsentiert die NRMSE-Werte für die aggregierten Mehrfamilienhäuser (blau), den Mittelwert der einzelnen MFH (grün) und ein atypisches MFH mit vergleichsweise schlechten Vorhersagen (rot). Zur Verdeutlichung des NRMSE-Anstiegs in Abhängigkeit von der

Tagestemperatur wurden Regressionslinien mittels der Methode der kleinsten Quadrate in die Grafik integriert.




Abbildung 25: NRMSE in Abhängigkeit der mittleren Tagestemperatur während der Vorhersage für die aggregierten MFH, den Mittelwert der MFH sowie ein atypisches MFH mit auffallend hohen NRMSE Werten

Abbildung 26 zeigt die NRMSE-Werte der einzelnen MFH ohne den Mittelwert und den aggregierten Datensatz pro Kalenderwoche, gemittelt über alle 4 Jahre. Auch in dieser Darstellung ist zu sehen, dass die Vorhersagen im Winter, d.h. bei niedrigeren Temperaturen, wesentlich genauer sind als in den Übergangsjahreszeiten.

Erklären lässt sich dieses Phänomen mit dem gewählten physikalischen Modellierungsansatz des Heizbedarfs, in welchem sich unsere Skalierungsparameter bei mehr Bedarf, also tendenziell kühleren Temperaturen, besser und robuster trainieren lassen. Eine Schwierigkeit liegt darin, dass genaue Heizkurven und konkrete Regelungsparameter nicht bekannt sind, was bei Temperaturen um die Heizgrenze schnell zu grösseren Fehlabschätzungen führen kann, da konkrete Wärmepumpen bei Überschreitung dieser Temperaturen seltener oder gar nicht betrieben werden.

Deshalb sehen wir für die Übergangszeiten zusätzliche Anpassungen unseres Vorhersagealgorithmus vor, darunter eine spezifische Auswahl der Trainingstage aufgrund der Temperaturen sowie die Berücksichtigung der Effekte von zu erwartenden Temperaturunterschieden zwischen Trainings- und Prädiktionszeitraum. Hervorzuheben ist jedoch, dass die Vorhersagen bei niedrigen Temperaturen, wenn der Energiebedarf der WP am höchsten ist, am genauesten sind.




Abbildung 26: NRMSE von Wärmepumpen der einzelnen MFH (ohne Mittelwert und aggregiertem Datensatz) über den gesamten Auswertungszeitraum für die jeweilige Kalenderwoche.

Im Rahmen der Validierung wurden weitere Erkenntnisse hinsichtlich der Vorhersagegenauigkeit von Wärmepumpen gewonnen. Es zeigt sich, dass die Genauigkeit der Vorhersagen mit steigendem Energieverbrauch zunimmt, was auf eine verbesserte Performance des Vorhersagealgorithmus bei höherer Betriebsintensität der Wärmepumpen schliessen lässt. Des Weiteren wurde beobachtet, dass bei einigen Mehrfamilienhäusern, in denen die Wärmepumpen überdurchschnittlich viele Ein- und Ausschaltzyklen aufweisen – vermutlich aufgrund einer Überdimensionierung –, die Vorhersagegenauigkeit tendenziell geringer ist. Dies deutet auf Schwierigkeiten bei der Modellierung unregelmässiger Betriebsmuster hin. Zudem hat sich gezeigt, dass Störungen, die dazu führen, dass Wärmepumpen nicht einschalten, zu erheblichen Abweichungen in den Vorhersagen führen.

Boiler:

Abbildung 27 zeigt die NRMSE Werte der Boiler-Validierung für individuelle MFH, ein aggregiertes Profil sowie einen Mittelwert über alle MFH, dargestellt in aufsteigender Reihenfolge. Im Unterschied zur Auswertung der Wärmepumpenvorhersage, wurden die Differenzen über einen ganzen Tag summiert und die Normalisierung erfolgte über den Median der täglichen Summen aller Ground Truth Daten.




Abbildung 27: NRMSE Werte der Boiler Komponente für individuelle MFH, ein aggregiertes Profil (agg_MFHs) sowie einen Mittelwert über alle MFH (mean_MFHs), dargestellt in einer aufsteigenden Reihenfolge.

Analog zu den Beobachtungen bei den Wärmepumpen zeigt sich, dass im aggregierten Profil bessere Ergebnisse erzielt werden, was durch statistische Ausgleichseffekte erklärbar ist. Genauso ist der insgesamt geringere Variationsbereich sowie der kleinere Interquartilsabstand des Mittelwert-Datenset (mean_MFHs) darauf zurückzuführen.

Viele der identifizierten Ausreisser innerhalb der Daten resultieren aus Einzeltagen mit aussergewöhnlich hohem gemessenen gesamt-Warmwasserverbrauch, verglichen mit den vorangegangenen sieben Tagen beziehungsweise den Trainingstagen (Vergleich Abbildung 28). Eine mögliche Ursache für dieses Phänomen sind ungenau disaggregierte Input Spuren. Auch sind aufgrund des verwendeten Vorhersagealgorithmus, welcher hauptsächlich auf gemittelten, historischen Profilen basiert, insbesondere Vorhersagen für Tage ohne Boiler-Ladungen, also Tage ohne Verbrauch, mit einem grossen Fehler behaftet.




Abbildung 28: Beispiel einer ungewöhnlichen Boiler-Spur mit entsprechender Schwierigkeit der Vorhersage.

Rest-Verbrauch:

Abbildung 29 zeigt die NRMSE Werte der Rest-Verbrauch-Validierung für individuelle MFH, ein aggregiertes Profil sowie den Mittelwert über alle MFH, dargestellt in aufsteigender Reihenfolge. Die Normalisierung erfolgte anhand des Mittelwerts der Ground Truth Daten des Vorhersagetages. Tage, an denen die Ground Truth Daten Nullwerte aufweisen, was auf unzureichende Datenerhebung hinweist, wurden von der Analyse ausgeschlossen.

Insgesamt zeigt die Rest-Verbrauchsvorhersage sehr zufriedenstellende Resultate. Da im Rest-Verbrauch jedoch alle übrigen Verbraucher eines Haushalts, abzüglich Wärmepumpen und Boiler, enthalten sein können, wurde auf eine detailliertere Analyse der Abweichungen verzichtet. Eine Schwierigkeit in der Analyse des Rest-Verbrauchs liegt in der Variabilität der Bezugsniveaus der verschiedenen Komponenten. Zusätzlich unterscheidet sich der Mix der Komponenten von Gebäude zu Gebäude. Der Aufbau des Vorhersage-Frameworks erlaubt es jedoch sehr einfach zusätzliche neue Verbraucher als separate Komponenten zu ergänzen, sofern hinreichend genaue Disaggregations-Spuren erzeugt werden können. So kann der Anteil des «unbekannten» Rest-Verbrauchs nach und nach verkleinert werden.

In unserer Analyse haben wir für *MFH_01* festgestellt, dass grosse Ausreisser von bis zu 206 auf inkorrekte Input-Daten zurückzuführen waren. *MFH_15* enthält Ausreisser im negativen Bereich von bis zu -15, sowie im positiven Bereich von bis zu 55. Der Interquartilsabstand von *MFH_15* ist verglichen mit den anderen MFH auffallend gross. Dies lässt sich durch die Präsenz einer Photovoltaik-Anlage erklären, welche den Rest-Verbrauch stellenweise negativ werden lässt. Entsprechend hohe Fehler in der Vorhersage sind in diesem Fall zu erwarten, da negative Werte noch nicht richtig berücksichtigt werden.

Für die übrigen Gebäude sowie die aggregierte Datenspur konnte gezeigt werden, dass mit dem verwendeten, einfachen Ansatz sehr gute Ergebnisse von weitestgehend unterhalb 0.4 erreicht werden konnten.




Abbildung 29: NRMSE Werte vom Rest-Verbrauch für individuelle MFH, ein aggregiertes Profil (agg_MFHs) sowie einen Mittelwert über alle MFH (mean_MFHs), dargestellt in einer aufsteigenden Reihenfolge. Wenige grosse Ausreisser wurden aus Übersichtsgründen nicht dargestellt.

Optimierte Verbrauchsplanung:

Das entwickelte Verfahren zur Lastspitzen-Reduktion lässt sich in 4 Schritte aufteilen. Als erstes werden die entwickelten Vorhersagealgorithmen auf die vorhandenen Komponenten angewendet. Im erzeugten Profil werden dann automatisch Lastspitzen und Bereiche von möglichen Interaktionen von flexiblen Verbrauchern erkannt. Zufällig werden damit sehr viele mögliche Szenarien von Ein- und Ausschaltbefehlen der nutzbaren Komponenten ausgewählt und simuliert. Abschliessend wird jedes Szenario anhand der Reduktion des maximalen Verbrauches bewertet und nach kleineren Anpassungen zum Verhindern von unnötigen Eingriffen die optimierten Schaltanweisungen vorgeschlagen. Zu beachten gilt, dass mit diesem Ansatz kein effektives Optimum für die Schaltungen gefunden wird, eine ausreichend grosse Anzahl an ausgewählten Szenarien jedoch eine gute Annäherung erlaubt. Grund für dieses Vorgehen ist der viel geringere Rechenaufwand.

Als Test einer konkreten Umsetzung wurde ein Datenset aus 15 Messpunkten zusammengestellt. Darin sind 5 Messpunkte enthalten, welche über eine Wärmepumpenspur verfügen. Diese 5 Wärmepumpen werden als flexible Komponenten betrachtet, die restlichen Lastkurven sorgen für eine realistischen Gesamtverbrauch. Mit maximalen Abschaltzeiten von 2h pro Wärmepumpe und 100% Kompensation vor erneuter Verwendung wurden die Schaltbedingungen der Komponente Wärmepumpe sehr restriktiv gesetzt. Damit sollte das Potential angenähert werden, welches mit dem Grossteil der Wärmepumpen in jedem Fall geliefert werden kann. Die Kompensation wird in dieser Simulation über ein Zuschalten mit maximaler historischer (über die Trainingszeit) Leistung erreicht. In Abbildung 30 ist eine Lastspitzenreduktion dargestellt, zusammen mit dem entsprechend optimierten Schaltplan für 5 Wärmepumpen. Darin bezeichnet "consumption" (oben, blau) die Vorhersage des totalen Verbrauchs der 15 Gebäude, "flexibility" (oben, grün) bezeichnet die Vorhersage unter Berücksichtigung des optimierten Schaltplans (unten).




Abbildung 30: Beispiel einer erfolgreichen Lastspitzen-Reduktion durch optimierten Schaltplan von 5 Wärmepumpen

In Abbildung 31 sind die Resultate für ein Datenset bestehend aus 5 Häusern mit Wärmepumpe (Rest-Verbrauch + Wärmepumpe) und 10 weitere Häuser (nur Rest-Verbrauch) dargestellt. Dazu wurde ein Peak-Shaving für 18 zufällig ausgewählte Tage durchgeführt. Die Vorhersage für den jeweiligen Tag beruht auf 14 Trainingstagen und wird entsprechend unserem Flexibilitätsmodell mit den gegebenen Rahmenbedingungen optimiert. Dabei war das Ziel Peaks an diesem Tag (ein Tag beinhaltet die 24h des Kalendertages plus die nächsten 5 Nachtstunden) zu reduzieren. Der Mittelwert der Reduktion beträgt 10.39%, der Medianwert 9.47%.

Day	New Peak [kWh]	Reduction [%]
18.09.2022	24.16	6.84
07.02.2022	63.27	4.16
08.02.2022	66.49	8.31
08.12.2022	59.66	9.62
01.01.2022	50.91	14.39
30.04.2023	25.03	7.66
13.12.2021	75.1	10.88
06.03.2023	72.54	7.88
24.11.2021	38.86	16.41
21.11.2022	28.35	7.44
31.05.2021	30.25	16.01
19.03.2022	71.71	4.47
22.12.2022	69.1	9.31
21.09.2021	28.08	17.13
14.12.2021	71.98	2.99
24.10.2022	37.18	14.31
13.06.2022	15.71	16.8
18.10.2021	22.11	12.34
Mean		10.39
Median		9.47

Abbildung 31: Simulierte Peak Reduktion für 18 zufällig ausgewählte Tage

Nach erfolgreicher Validierung wurde eine Schnittstelle zum SES erarbeitet und implementiert. Somit steht nun eine Lösung zum Testen von optimierten Lastmanagement Optionen von Wärmepumpen zur Verfügung. In Abbildung 32 ist ein Ausschnitt der Spezifikation ebendieser Schnittstelle zu finden.

Input

Der Input besteht aus jeweils einem Dataframe für die Testperiode und einem für die Vorhersageperiode.

Erstes Dataframe – Trainingsperiode

Spaltenname	Muss	Beschreibung	Type	Bemerkungen
DateTime	Ja	Datum und Zeit	DatetimeIndex	1h Auflösung
consumption_{id}	Nein	Verbrauchs-Profil Gesamtverbrauch	Float	Angaben in kWh; Die {id} dient der Unterscheidung der Spalten; 0..n solcher Spalten
consumption_hp_{id}	Ja	Verbrauchs-Profil Wärmepumpe	Float	Angaben in kWh; 1..n solcher Spalten
consumption_boiler_{id}	Nein	Verbrauchs-Profil Boiler	Float	Angaben in kWh; 0..n solcher Spalten
ambient_temperature	Ja	Aussentemperatur	Float	Angaben in °C

Zweites Dataframe – Vorhersageperiode

Spaltenname	Muss	Beschreibung	Type	Bemerkungen
DateTime	Ja	Datum und Zeit	DatetimeIndex	1h Auflösung
ambient_temperature	Ja	Aussentemperatur	Float	Angaben in °C

Output

Die geschalteten WP-Profile werden zusammen mit den vorhergesagten Haushaltsströmen in einem Dataframe ausgegeben. Zusätzlich wird ein Dataframe mit den Abschaltungen der WP ausgegeben.

Erstes Dataframe – Flexibilitätsprofile

Spaltenname	Beschreibung	Type	Bemerkungen
DateTime	Datum und Zeit	DatetimeIndex	1h Auflösung
consumption_hh_{id}	Verbrauchs-Profil Vorhersage Haushaltsstrom	Float	Angaben in kWh
consumption_hp_{id}	Verbrauchs-Profil geschaltete Wärmepumpe	Float	Angaben in kWh
ambient_temperature	Aussentemperatur	Float	Angaben in °C

Zweites Dataframe – Abschaltungen

Spaltenname	Beschreibung	Type	Bemerkungen
DateTime	Datum und Zeit	DatetimeIndex	1h Auflösung
consumption_hp_{id}	Schaltzustand der Wärmepumpe	Int	1: WP wird abgeschaltet 0: WP wird nicht abgeschaltet

Abbildung 32: Ausschnitt der Spezifikation der Schnittstelle für Verbrauchsplanoptimierung

4.6 Flexibilitätslabel / Haustyperkennung

Im Arbeitspaket zur Haustyperkennung wurde ein Verfahren entwickelt, um das Flexibilitätspotenzial von einzelnen Messpunkten abschätzen und vergleichen zu können. Dabei war das Ziel, dass verschiedene Anwendungsfälle betrachtet werden können. Um dies zu erreichen haben wir die Flexibilitätsmatrix eingeführt, deren Einträge durch die erkannten Komponenten, entsprechende Verbrauchsprofile und falls vorhanden durch historische Daten befüllt wird. Für verschiedene Anwendungsfälle können dann verschiedene Abfragen definiert werden, welche die Einträge der Flexibilitätsmatrix unterschiedlich gewichten und bewerten und somit zu unterschiedlichen Flexibilitäts-Scores führen.

Flexibilitätsmatrix

Die Flexibilitätsmatrix gibt Auskunft über die pro Gebäude vorhandenen Komponenten und deren jeweiligen für die Flexibilität relevanten Eigenschaften. Diese geben Auskunft über die saisonale und zeitliche Verfügbarkeit sowie die Dauer und Amplitude des Flexibilitätspotenzials und Eigenschaften der zugrunde liegenden Komponenten. Ausserdem wird festgehalten, wie lange es dauert, bis die Flexibilität erneut genutzt werden kann (Recovery-Time). Einige dieser Eigenschaften werden als 24h-Profile festgehalten, andere als Zahlen oder beschreibend.

Es gibt verschiedene Profile, die einen unterschiedlichen Detaillierungsgrad resp. Art aufweisen. Dadurch wird die Flexibilitätsmatrix modular, resp. hierarchisch, aufgebaut, abhängig von den verfügbaren Daten (öffentliche Daten, SES Komponenten-Erkennung, detaillierte Lastganganalyse). Die Einordnung der Flexibilitätsmatrix in den Ablauf der verschiedenen Arbeitspakete, d.h. der in diesem Kapitel vorgestellten Arbeitsschritte, zusammen mit den jeweiligen Abhängigkeiten ist in Abbildung 33 dargestellt. Die verschiedenen Profile werden unten detailliert beschrieben.

Der hier beschriebene Ansatz der modular aufgebauten Flexibilitätsmatrix erlaubt in einfacher Weise Erweiterungen aufzunehmen. Beispielsweise die oben erwähnte Recovery-Time, bis die Flexibilität erneut genutzt werden kann, kann aus historischen Daten bestimmt werden. Als neue Variable kann z.B. eine Priorisierung der Kunden des EVU vorgenommen werden oder es kann ein Flexibilitäts-Tarif hinterlegt werden, falls es hierzu unterschiedliche Verträge gibt.




Abbildung 33: Übersicht der Zusammenhänge und Abhängigkeiten der Arbeitspakete 2-6 (siehe Kapitel 4.1 – 4.5)



Profile

In der hier vorgestellten Flexibilitätsmatrix gibt es für jede Komponente ein 24h-Profil, das die Aktivität der Komponente beschreibt. Abbildung 34 zeigt die ersten drei der unten aufgeführten Profile.

Die d-Profile (default-profile) haben für jede Stunde den Eintrag 0 (nicht aktiv) oder 1 (aktiv).

Die s-Profile (scaled-profile) skalieren die d-Profile, indem sie diese mit dem 90%-Quantil-Wert der historischen Daten multiplizieren. Dieser Wert ist so gewählt, damit das Profil einen hohen Wert aufzeigt, jedoch nicht durch einzelne Ausreisser bestimmt ist. Das s-Profil wird verwendet, wenn zu wenige Datenpunkte vorhanden sind, um ein zuversichtliches m-Profil (siehe unten) erstellen zu können.

Die m-Profile (mean-profile) enthalten nicht mehr nur binäre Werte, sondern Mittelwerte der einzelnen Tagesstunden über den Zeitraum der historisch verfügbaren Daten. Hier haben wir zum ersten Mal ein Profil, das einen differenzierten Verbrauch aufzeigt, so dass also beispielsweise nicht mehr alle Wärmepumpen dasselbe Aktivitätsmuster besitzen.

Die v-Profile (verbose-profile) werden hier nur als Ausblick vorgestellt. Sie enthalten detailliertere Angaben zu den entsprechenden Komponenten, so dass beispielsweise bei Ladestationen zwischen Wochentagen und Samstagen sowie Sonntag unterschieden werden kann. Bei Wärmepumpen können saisonal unterschiedliche Profile hinterlegt werden oder solche, die in Abhängigkeit zur Aussentemperatur stehen.

Die p-Profile (prediction-profile) sind keine allgemeinen Profile, sondern entsprechen den Vorhersage-Profilen, welche durch den in AP 5 und im vorangehenden Unterkapitel vorgestellten Algorithmus erzeugt werden. Die sehr einfache Integrierbarkeit dieser Vorhersageprofile ist ein bedeutender Vorteil des gewählten Formats der Einträge in der Flexibilitätsmatrix.




Abbildung 34: Beispiele der d-, s- und m-Profile einer Wärmepumpe, eines Boilers und einer EV-Ladestation

Scores

Um aus den Einträgen der Flexibilitätsmatrizen einfach vergleichbare Grössen zu extrahieren, lassen sich nun verschiedene Funktionen definieren, deren Input die Flexibilitätsmatrix und Output eine Zahl ist. Diese Zahl ist ein Flexibilitäts-Score und kann entsprechend für verschiedene Funktionen unterschiedliche Werte annehmen. Dieser Score ist also nicht ein beschreibender Wert für ein Gebäude, sondern als Vergleichswert bezüglich einer spezifischen Abfrage resp. Anwendung zu verstehen. Die flexibilitätsrelevanten Eigenschaften sind in der Flexibilitätsmatrix festgehalten.

Der hier beschriebene Ansatz mit den Profilen erlaubt spezifische Abfragen an die Flexibilitätsmatrix zu machen, die über ein allgemeines Label hinausgehen. Beispielsweise kann für ein Peak-Shaving die Flexibilität während den Abendstunden von 18 bis 21 Uhr bestimmt werden, welche sich von der Flexibilität tagsüber teilweise stark unterscheiden kann. Oder es lassen sich sehr generelle Scores definieren, welche beispielsweise ein Quartier hinsichtlich seines groben Flexibilitätspotenzials und den darin vorkommenden Komponenten untersuchen. Durch die Einbettung der Vorhersage-Profile (p-Profile) lassen sich in analoger Weise durch entsprechende Abfrage auch dynamisch Flexibilitäten bestimmen, z.B. für den nächsten Tag. Somit können die Resultate aus AP 5 (Vorhersage) direkt verwendet werden.

In Abbildung 34 sehen wir Beispiele von den verschiedenen Profilen, wobei auffällt, dass die d- und s-Profile eine Art Umriss aufzeigen, der auf eine zu hohe Flexibilität schliessen würde. Dieser Tatsache kann in den Abfragen an die Flexibilitätsmatrix Rechnung getragen werden indem entsprechende Profile bestraft, also schwächer gewichtet, werden. Siehe dazu das folgende Beispiel.

Beispiel: Bewertung von Flexibilitäten während des Abendpeaks

Zur Veranschaulichung einer solchen Abfrage resp. Score zeigen wir ein Beispiel, in welchem wir uns für die Flexibilität in den Abendstunden von 18:00 bis 21:00 Uhr interessieren. Im Allgemeinen würden wir alle Einträge der Flexibilitätsmatrix als Input für diese Funktion verwenden. Da wir uns hier jedoch nur für die drei Abendstunden interessieren, können wir auf die Recovery-Time verzichten, da diese irrelevant ist. Dies ist gerechtfertigt unter der Annahme, dass keine Recovery-Time länger als 21 Stunden beträgt.

Die Funktion, also unsere Abfrage, beinhaltet einerseits die Gewichtung der Stundenwerte der Profile, andererseits die Art der Profile an sich. Das heisst, dass nur die Stunden von 18-21 Uhr betrachtet werden und beispielsweise s-Profile, falls diese verwendet werden müssen, weil kein m-Profil vorhanden ist, mit einem Faktor bestraft werden.




Abbildung 35: Profile der drei Häuser aus dem vorgestellten Beispiel

Der hier berechnete Score der in Abbildung 35 gezeigten Profile von drei Beispielhäuser lautet

$$S = \sum \alpha_j \cdot K_j ,$$

wobei α_j die Gewichtung der Komponente j beschreiben. Im Vorliegenden Beispiel sind alle $\alpha_j = 1$, wobei wir die Irrelevanz der Boiler auch mit $\alpha_{Boiler} = 0$ ausdrücken könnten. Die Koeffizienten der Komponenten lauten

$$K_j = p_j(q) \cdot \frac{1}{3} \sum_{i=18}^{21} c_{ij} ,$$

wobei p_j den penalty-Faktor der Komponente j für den Profiltyp q und c_{ij} den i -ten Profilwert der Komponente j beschreiben. Die Bestrafungsfaktoren (penalty) werden entsprechend dem vorhandenen Profil gesetzt und lauten hier $p_j(m - profil) = 1$ sowie $p_j(s - profil) = 0.2$. Die Bestrafung der s-Profile kommt daher, dass dieses Profil das effektive Verbrauchsprofil ungefähr umhüllen soll. In Abbildung 34 ist gut zu sehen, dass ein sinnvoller Wert, der meistens erreicht wird beim m-Profil um die 20% des Wertes des s-Profils beträgt. Es kann damit gerechnet werden, dass eine Flexibilität genutzt werden kann, jedoch kann nicht zuversichtlich ein höherer Wert prognostiziert werden und diesen fehlenden Informationen wird mit den Bestrafungsfaktoren Rechnung getragen. Die resultierenden Scores sind in Abbildung 36 zusammengefasst.

	Haus 1	Haus 2	Haus 3
Flexibilitäts- Score	4.22	0.89	1.53

Abbildung 36: Tabelle der Flexibilitäts-Scores aus dem Beispiel

Beim Betrachten dieser Scores fällt auf, dass dem Haus 2 trotz seines höheren Wärmepumpenprofils eine kleinere Flexibilität zugeschrieben wird als beispielsweise dem Haus 3. Grund dafür sind ungenauere Angaben und somit eine schwierigere Schätzung des effektiven Flexibilitätspotenzials, was in der Abfrage durch den oben beschriebenen Bestrafungsfaktor zu tragen kommt, weil ein s-Profil verwendet werden muss. Haus 1 weist die grösste Flexibilität aus, da nebst der Wärmepumpe auch noch eine Ladestation als weitere Komponente zur Verfügung steht. Die Flexibilitäten der Boiler sind bei allen Häusern irrelevant oder Null, da sich die betrachtete Zeit ausserhalb der Aktivitätszeiten der Boiler befindet.

Um den Vergleich einzelner Gebäude zu vereinheitlichen, kann die Funktion für den Flexibilitäts-Score auch normiert werden. Wir haben in diesem Beispiel darauf verzichtet, weil der hier verwendete Score neben seiner Vergleichbarkeit zusätzlich den Vorteil hat, dass er eine Abschätzung über die zu erwartende Leistung der Flexibilität in kW beinhaltet.

4.7 Lastverschiebung / Ansteuerung

Mit der Umgruppierung der Rundsteuer-Boiler-Gruppen konnte eine einfache Lösung für die Lastverschiebung realisiert werden. Im Rahmen des Feldtests wurden Vorschläge zu Umgruppierungen von Boilern erstellt. Abbildung 37 zeigt ein Beispiel für eine Ladezeit optimierte Boiler-Gruppierung.



MP ID	Messung von	Messung bis	Gerätetyp	Leistung (W)	Gewissheit	Häufigste Aktivität	24-Tage-Block mit den meisten Aktivitäten	Mittlere Ladezeit
1956	3/4/2022 23:00	7/18/2022 22:00	Boiler	4796	0.95833	23:30	31.03.2022 - 23.04.2022	269
2161	3/4/2022 23:00	7/18/2022 22:00	Boiler	9152	0.79167	23:30	31.03.2022 - 23.04.2022	257
2072	3/4/2022 23:00	7/18/2022 22:00	Boiler	2024	0.70833	2:45	31.03.2022 - 23.04.2022	229
1924	3/4/2022 23:00	7/18/2022 22:00	Boiler	3373	0.91667	23:30	24.04.2022 - 17.05.2022	213
2932	3/4/2022 23:00	7/18/2022 22:00	Boiler	10770	0.875	2:45	31.03.2022 - 23.04.2022	204
3423	3/4/2022 23:00	7/18/2022 22:00	Boiler	5152	0.875	3:15	18.05.2022 - 10.06.2022	204
2023	3/4/2022 23:00	7/18/2022 22:00	Boiler	4161	0.875	3:15	18.05.2022 - 10.06.2022	188
3502	3/4/2022 23:00	7/18/2022 22:00	Boiler	4773	0.95833	2:15	18.05.2022 - 10.06.2022	170
2414	3/4/2022 23:00	7/18/2022 22:00	Boiler	2668	1	2:45	31.03.2022 - 23.04.2022	166
2406	3/4/2022 23:00	7/18/2022 22:00	Boiler	2965	0.75	23:15	18.05.2022 - 10.06.2022	164

Abbildung 37: Optimierte Boiler-Gruppierung nach der mittleren Ladezeit

Mit dem Ladestation-Flexibilitätsmodell, dass Kunden belohnt, die nicht zwischen 17 und 23 Uhr laden, kann eine signifikante Lastspitzenreduktion erreicht werden. Bei einem VNB wurden die Werkvorschriften dahingehend angepasst, dass zwischen 17 und 21 Uhr Ladestationen gegen einen Flexibilitätsrabatt gesperrt werden können. Als weiteren positiven Effekt kann das Lastprofil für den Energieeinkauf verbessert werden. Während den Day Ahead Preis-Spitzen zwischen 17 – 19 Uhr muss weniger Energie eingekauft werden.




Abbildung 38 Day Ahead Preise in der Woche 5 2024 [11]

Bei den Messpunkten mit einer Batterie ist der positive Effekt der Lastspitzenreduktion von 18 bis 21 Uhr messbar. Leider wird die installierte private Speicherkapazität auch in absehbarer Zukunft viel zu gering sein, um einen spürbaren Lastspitzen-Reduktionsbeitrag zu leisten. Mit der Verbreitung von bidirektionalen Ladestationen kann auch die brachliegende Batteriekapazität von E-Autos zukünftig genutzt werden.

Die Ansteuerung der Wärmepumpen via dem Smart Grid Ready Signal hat sich als schwieriger als geplant herausgestellt. Mit einzelnen Wärmepumpen, die via der proprietären Herstellerschnittstellen angesteuert werden, kann das Steuerungskonzept überprüft werden.

4.8 Weitere Erkenntnisse

4.8.1 Ansteuerbare Wärmepumpe (via Herstellerschnittstelle)

- Mehrfamilienhaus, Minergie P
- Aussentemperatur zwischen -6.2 und +6.1 Grad
- Nachtabsenkung zwischen 19:30 – 4:30 Uhr (9 Stunden)




Abbildung 39: TEM RC7000 Wärmepumpen Controller




Abbildung 40: Wärmepumpe mit einem dynamischen Zeitprogramm

Legende:

- Gelbbraune Linie: Leistungsaufnahme der Wärmepumpe
- Blaue Linie: Aussentemperatur zwischen -6.2 und +6.1 Grad
- Grüne Linie: PVA-Leistung
- Wärmepumpen Lastgang vom 28.1. – 30.1.2023



Die 9-stündige Nachtabsenkung sollte aufzeigen, wie weit diese Massnahme für die Bewohner spürbar ist und ob beim Sparbetrieb die minimale Heiztemperatur von 17 Grad erreicht wird. Am 30.1.2023 um 3 Uhr nachts (rotes Rechteck), bei einer Aussentemperatur von -6 Grad, schaltete die Wärmepumpe ein. Das Fazit aus dem Versuch ist, dass bei einem gut isolierten Minergie P Gebäude, eine Abschaltdauer zwischen 4-8 Stunden bei Minustemperaturen ohne grössere Komforteinbusse realisierbar ist. Nach der längeren Sperrzeit läuft die Wärmepumpe 4 Stunden, bis das Heizdefizit ausgeglichen ist. Diese Erkenntnisse werden nun auf Haustypen mit einem niedrigen Flexibilitätsscore übertragen.

4.8.2 Vergleichsanalyse Anschlussgesuche mit Ergebnissen der Algorithmen

Vor dem Start des Feldtests wurde ein detailliertes Inventar über die effektiv installierten Anlagen (unterteilt in «schaltbare» und «nicht schaltbare» Anlagen) auf Basis der Anschlussgesuche vorgenommen. Dies wurde mit den Algorithmen verglichen und analysiert, wo die Algorithmen zusätzliche Kenntnisse über den Anlagebestand liefern bzw. die Informationen der Anschlussgesuche ergänzen.

Des Weiteren wurden 5 Wetterstationen mit Temperatur (°C) und Sonneneinstrahlung (W/m²) für die Standorte Vilters, Zug, Chur, Luzern und Altdorf in das System integriert, die für die Disaggregation und Vorhersage der Lastkurven von Wärmepumpen und PV-Anlagen benötigt werden.

- Boiler werden mit einem Spike-Algorithmus detektiert, mit den gemeldeten Gesuchen verglichen, visuell verifiziert und mit Metadaten (max. Leistung, Schaltzeit, usw.) ergänzt.
- Bei den Technischen Betrieben Vilters-Wangs können alle Wärmepumpen und Boiler durch die Rundsteuerung angesteuert werden.
- EWA setzt Smart-Meters mit zwei Relais ein. Abklärungen über den Einsatz bei Pilot-Gebäuden laufen.

Erkenntnisse und Bewertung:

Die gemeldeten Wärmepumpen werden direkt via Smart Energy System (SES) Portal visuell verifiziert und mit der automatischen Erkennung verglichen. Werden Abweichungen identifiziert, erfolgt eine Rücksprache mit dem Besitzer und es werden ggf. Anpassungen am gewählten Tarifmodell vorgenommen. Zudem werden Veränderungen (z. B. Austausch von Boilern oder Wärmepumpen mit veränderten Werten, Neu-Installation von E-Ladestationen) durch das zyklische Scannen aller Messpunkte automatisch erkannt.

Die folgenden Abbildungen zeigen exemplarische Beispiele mit Abweichungen zwischen Anschlussgesuchen bzw. Installationsanzeigen und den tatsächlichen identifizierten Leistungswerten durch das SES-System:



Elektrizitätsversorgungsunternehmen (EVU)	
Anmeldung für elektrische Wärme (Raumheizung und Wassererwärmung)	
2. Gebäude	
☐ Neubau ☒ Altbau ☐ Industrie ☐ Gewerbe ☐ Landwirtschaft ☒ EFH ☐ MFH mit Wohneinheiten ☐ Die thermischen Eigenschaften entsprechen den heutigen gesetzlichen Normen und Anforderungen (Bund, Kanton, Gemeinde, SIA) ☒ ja	
3. Wassererwärmung (Brauchwasser)	
System ☐ elektrisch ☒ Wärmepumpe ☐ Sonnenkollektoren ☐ kombiniert mit ☒ Speicher ☐ WWAutomat Anzahl1.... Inhalt / Leistung ..400...[l]/6.....[kW][l]/[kW] Leistungsreihe/Aufheizzeit[h][h][h][h]	
4. Elektrische Widerstandsheizung	
Fabrikat / Typ Heizungsart ☐ Direktheizung ☐ Einzelspeicher ☐ Zentralspeicher ☐ Fussbodenheizung ☐ aut. Aufladesteuerung Leistung/Freigabezeit [kW]/ [h] ☐ Speicher Nacht [kW]/ [h] Direkte Ergänzungsheizung [kW]/ [h] ☐ Speicher Tag [kW]/ [h]	
5. Wärmepumpe	
Fabrikat / Typ Elcotherm AG / Aerotop S12.2 Anwendung für ☒ Wassererwärmung ☒ Heizung (Kühlung) ☒ monovalent ☐ bivalent ☒ elektr. Ergänzungsheizung mit/ohne Verriegelung6..... [kW] Elektrische Daten Kompressor(en) Normdaten (z.B. A7 W35)19.1 kW Spannung3... x 400...[V] Aufnahmeleistung P _{NT}2.0 [kW] cos phi bei P _{NT} über 10 kW0.9..... Betriebsstrom3.17 [A] Anzahl Kompressoren1..... berücksichtigte Freigabezeit2.....[h] Anlauf ☐ Direktanlauf ☐ Widerstandsanlasser ☐ Sanftanlasser ☒ ...Inverter..... max. Anlaufstrom I _A5..... [A] Anzahl Anläufe pro h6..... Anlaufverzögerung nach Netzausfall .60 - 120. [Sek.] Frequenzumrichter ☐ nein ☐ ja, geregelte Leistung [kW]	
6. Entscheid des EVU	
☐ Anschluss möglich Bemerkungen ☒ Anschluss unter folgenden Bedingungen möglich <i>WP Sparte baedle</i> max. zul. Anlaufstrom I _A [A] <i>11-12h/18-46</i>	

Abbildung 41: Beispiel Anschlussgesuch Wärmepumpe

Die gemeldete Wärmepumpe in Abbildung 41 wurde direkt via Smart Energy System (SES) Portal visuell verifiziert und mit der automatischen Erkennung verglichen. Dabei stellte sich heraus, dass die im Anschlussgesuch (Abbildung 41) angegebene Leistung von 6 kW effektiv 6.8 kW beträgt.



INSTALLATIONSANZEIGE				Eingang:	Abo. Nr.
WERK <i>EW Vilters-Wangs</i>				IA-Nr. <i>60/2009</i>	
HAUSANSCHLUSS				SCHUTZMASSNAHME:	
Standort: <i>AZK-Autobahn-stand</i>				☒ Nullung (TN) ☐ Schutzterdung (TT)	
Hausleitung: ☐ bestehend _____ mm ² ☒ neu <i>10</i> mm ²				Erderart: ☐	
Bezügerl.: ☐ bestehend _____ mm ² ☒ neu <i>10</i> mm ²				☒ Fundamentterder ☒ Metallwasserleitung	
☐ bestehend _____ A ☒ neu/verstärken <i>40</i> A				Pot.-Ausgleich: ☐ best. ☒ neu	
☒ Kabel ☐ Freileitung				Messeinrichtung: ☐ bleibt ☒ neu	
Nullungs-erdleitung: ☐ bestehend _____ mm ² ☒ neu <i>16</i> mm ²				Standort: <i>AZK</i>	
VERBRAUCHER				STEUERAPPARATE und -BEFEHLE	
☒ Gemäss beiliegender Liste (sperrpflichtige u. umschaltbare Apparate immer aufführen)				SU/RE/FS Befehl M D V Zuschl.	
Anz.	U*	Volt	kW/kVA		
<i>1 Wärmepumpe</i>		<i>400</i>	<i>7,2</i>		
<i>1 Boiler</i>		<i>400</i>	<i>6,0</i>		
<i>1 WH + WT</i>		<i>400</i>	<i>4,0</i>		
Gleichzeitigkeitsfaktor ca. <i>0,5</i> Installierte Leistung Total: <i>30kW</i>				Anz. VERBRAUCHER DEMONTAGEN kW	
Anz.	TARIFAPPARATE	M D V	Werk-Nr.	Grösse (A)	Tarif ET DT
<i>1 DT-Zähler</i>	☒			<i>20/80</i>	☒
<i>1 Empfänger</i>	☒				
				Inbetriebnahme ca.: <i>Ende Sept. 2009</i>	

Abbildung 42: Beispiel Installationsanzeige Wärmepumpe und Boiler

Abbildung 42 zeigt ein exemplarisches Beispiel einer Installationsanzeige für eine Wärmepumpe und einen Boiler aus dem Jahre 2009. Die effektiv über den Erkennungsalgorithmus identifizierten und visuell verifizierten Werte liegen jedoch deutlich unter den in der Installationsanzeige aufgeführten Werte:

- Wärmepumpe (WP)
Anzeige: 7.2 kW
Effektiv: 5.2 kW
- Boiler
Anzeige: 6 kW
Effektiv: 3.1 kW

Die Gründe für die Abweichungen sind vielfältig. So ist beispielsweise bei Boilern oft nicht bekannt, ob der Anschluss 1 oder 3 phasig erfolgt ist. Auch der Ersatz eines Boilers durch einen Wärmepumpenboiler muss nicht gemeldet werden und oft sind die Installationsanzeigen von Boilern sogar bis zu 40 Jahre alt.





**Elektrizitätswerk
Vilters - Wangs**
www.ev.w.ch

Checkliste Smart-Meter Rollout

Empfänger Programme
Empfänger Typ

73 34
97 60
RM 6 50

Wärmepumpe
☒ Ja Leistung:

5.6 kW

☐ Nein

Elektroboiler
☒ Ja Leistung:

6 kW

☐ Nein

Strom-Zähler Alt

Zähler_Nummer	1.8.1	1.8.2	2.8.1	2.8.2
1220	108335	783686		

Strom-Zähler Neu

Zähler_Nummer	1.8.1	1.8.2	2.8.1	2.8.2
33 401 145	0	0	0	0

MUC installiert ☒ Ja ☐ Nein

Neuer Wasserzähler installiert ☒ Ja

• **Wärmepumpe**
Aufnahme: 5.6 kW
Effektiv: 3.2 kW

• **Boiler**
Aufnahme: 6 kW
Effektiv: 4.2 kW

Smart Energy System (SES)
Gerätetypen werden vom
Verrechnungssystem übernommen und
mit Metadaten ergänzt

Gerätetypen

Gerätetyp	Gewissheit	Installierte Leistung	Gültig ab	Gültig bis
Wärmepumpe	Sicher Ja	3'200 Watt	24.07.2021	
Boiler	Sicher Ja	4'200 Watt	24.07.2021	

22.7.21

Abbildung 43: Beispiel Installationsanzeige Smart-Meter Rollout

Ladestationen

Bei den Technischen Betrieben Vilters-Wangs wurde festgestellt, dass einzelne Ladestationen gar nicht gemeldet werden. Anhand der Gerätetyp-Erkennung können nun diese Besitzer direkt angesprochen werden.

4.8.3 Generisches Einsparpotential Netzausbau

Ein intelligentes Lastmanagement kann durch Optimierung der Leistungsnachfrage Netzüberlastungen minimieren wodurch Investitionen in den Netzausbau reduziert und effizienter gestaltet werden können. Die Implementation unterschiedlicher Massnahmen, wie Lastverschiebung, Lastreduktion, intelligente Steuerung und dezentrale Energieerzeugung stellen eine effektive Strategie dar, um den Bedarf an Netzausbau und damit verbundene Investitionen zu minimieren.

Im Rahmen des Projekts wurde versucht, ob die Einsparungen beim Netzausbau generisch (d. h. unabhängig von der spezifischen Netztopologie im Projekt) beziffert werden können. Eine quantifizierte Bezifferung des generischen Einsparpotentials ist jedoch nur exemplarisch anhand detaillierter Analysen unter Berücksichtigung der spezifischen Netzcharakteristika und Verbrauchsmuster möglich, so wie es im Rahmen des GIASES-Projekts vorgenommen wurde.

Hochrechnung (beispielhaft EVU Vilters-Wangs)

Im GIASES Projekt wurden der Ausbau der Elektromobilität und der Photovoltaik als die zwei wesentlichen Haupttreiber für einen Netzausbau bis zum Jahre 2030 identifiziert:

Elektromobilität:

Hier sind insbesondere die Lastspitzen in den Zeiten zwischen 18 – 21 Uhr ursächlich. Die Engpässe treten vor allem in den Monaten November bis Februar auf. Der Leistungsmehrbedarf wurde anhand der Daten von Vilters-Wangs berechnet. In der Gemeinde Vilters-Wangs waren im September 2018 insgesamt 3'455 Fahrzeuge immatrikuliert. Davon waren 2'728 Personenwagen. Von den 4'820 Einwohner besitzt somit jede Person im Schnitt 0.6 Personenwagen [12] (Seite 6). Die Einwohnerzahl per 31.12.2023 beträgt 5'023 Personen. Eine Studie der EBP Schweiz AG [13] (Seite 11) rechnet im Jahre 2030 mit einem Elektrofahrzeuganteil von 30%. Auf die Gemeinde Vilters-Wangs übertragen,

wird mit einem Elektrofahrzeugbestand von etwa 1'000 Fahrzeugen ($5'550 \text{ Personen} \cdot 0.6 [\text{Anteil Personenwagen}] \cdot 0.3 [\text{Anteil Elektrofahrzeuge}]$) im Jahre 2030 gerechnet. Die Disaggregation der aktuellen Messpunkte mit Ladestationen hat gezeigt, dass die Elektrofahrzeuge im Schnitt zwei Mal pro Woche und hauptsächlich an Werktagen zwischen 17:30 – 21:00 Uhr geladen werden. Hochgerechnet auf das untersuchte EVU im Jahre 2030 verursacht dies einen zusätzlichen Leistungsbedarf von 30% - 40%. Ohne Massnahmen können einige Trafostationen diesen zusätzlichen Leistungsbezug nicht abdecken.




Abbildung 44: Lastgänge von Transformatoren mit einer Nennleistung von 400 kVA

Von den 19 untersuchten Transformatorenstationen hatten vier eine Leistungsreserve von weniger als 30%. Erste Massnahmen wurden bei diesem EVU schon ergriffen. Basierend auf den GIASES Ergebnissen wurden die Werkvorschriften für Ladestationen angepasst. Neu installierte private Ladestationen können bei Bedarf zwischen 17 – 21 Uhr gestaffelt abgeschaltet werden. Mit dieser Massnahme kann der Netzausbau (Leistungsausbau der Transformatoren) über das Jahr 2030 hinausgeschoben werden. Bei durchschnittlichen Erneuerungskosten von CHF 50'000.00 pro Trafostation kann in diesem Versorgungsgebiet eine Kosteneinsparung von CHF 200'000.00 erzielt werden. Hochgerechnet auf die Schweiz müssten mit dieser Massnahme etwa 20% der Transformatoren nicht vorzeitig (vor Ablauf der Lebensdauer) erneuert werden.

Photovoltaik (PVA):

Bei einem lokal stark ausgeprägten Ausbau von Photovoltaik kann die Summe der Rückspeisungen ebenfalls zu einer Überlastung der Transformatorenstation führen, speziell wenn in einzelnen Nachbarschaften ein massiver Ausbau erfolgt. Die Überlastung erfolgt insbesondere an Wochenenden, da dort der Verbrauch in Gewerbe und Industrie reduziert ist.




Abbildung 45: Lastgang mit Rückspeisung PVA



Hochrechnungen (generisch)

Die Einsparungen des Verteilnetzbetreibers durch das vorgeschlagene Lastmanagement der Flexibilitäten kommt vor allem beim vorzeitigen Ausbau der Transformatorenstationen zum Tragen. Hochgerechnet auf die 600 EVUs in der Schweiz sind dies Einsparungen von über 100 Millionen CHF bis ins Jahr 2030.

Bei der Bewilligung von Ladestationen mit einem Lastmanagement (Gewerbe- und Mehrfamilienhäuser) wurden die Netzübergabepunkte ausgewertet und festgestellt, dass die berechneten Anschlussleistungen der Planungsbüros bis zu 50% höher waren als die maximale Lastspitze der letzten zwei Jahre. Dieser Leistungsspielraum kann nun für die E-Mobilität genutzt werden, ohne dass die Zuleitung zum Haus und Verteilkasten ausgebaut werden muss.

4.8.4 Vergleichsanalyse Netzplanungsgrundsätze mit Algorithmen

Im Rahmen des Projekts wurde untersucht, ob und wie fern mit den Netzplanungsgrundsätzen der Netzbetreiber der Gewinn durch die vorgeschlagenen Algorithmen geschmälert oder zunichte gemacht wird. Dazu wurde eine vergleichende Analyse zwischen dem Vorgehen gemäss Netzplanungsgrundsätzen und gemäss Algorithmen erstellt. In der folgenden Tabelle ist dokumentiert, durch welche Vorgaben die Norm EN50160 den Nutzen der algorithmischen Lösung reduzieren kann.

EN 50160 Merkmale	Auswirkungen GIASES-Algorithmen
Frequenz	Peak Shaving reduziert Frequenzabweichungen
Unterbrechungen	Kein Einfluss
Flicker	Kein Einfluss
Harmonische Oberschwingungen	Kein Einfluss
Interharmonische Oberschwingungen	Kein Einfluss
Spannungsschwankungen	Reduziert
Spannungseinbrüche	Reduziert
Kurzfristige Überspannungen	Peak Shaving reduziert Überspannungen
Spannungsasymmetrie	Kein Einfluss

Abbildung 46: Vergleichende Analyse Netzplanungsgrundsätze und Algorithmen gemäss EN 50160

4.9 Interaktionen mit den Verteilnetzbetreibern (VNB)

Im Verlaufe des Projektes wurden mit den einzelnen Verteilnetzbetreibern verschiedene Gespräche, Abklärungen und Rückfragen hinsichtlich der erarbeiteten Erkenntnisse geführt. Da beim TB Vilters-Wangs als einziges EVU ein komplettes Verteilnetz zur Verfügung stand, fanden hier die meisten Interaktionen statt. Diese decken sich im Wesentlichen auch mit den Erkenntnissen der anderen Projektteilnehmer und umfassten im Einzelnen folgende Inhalte:

- Aktivierung von Boiler-Gruppen bei hoher PV-Produktion zwischen 10 – 11:20 und 13 -14:30 Uhr
- Virtueller Lastgang aller PV-Anlagen im Verteilnetz
- Berechnung des totalen Verbrauches im Verteilnetz
- Wärmepumpen: Tests von Sperrzeiten für Wärmepumpen
Aufzeichnung eines virtuellen Lastganges aller Wärmepumpen im Verteilnetz
- Überarbeitung der Werksvorschriften für Ladestationen. Die Werksvorschriften für Ladestationen wurden bei einem EVU für das Jahr 2024 angepasst.



- Abgleich der erkannten neuen Flexibilitäten mit den VNB-Installationsanzeigen. Hier zeigte sich insbesondere, dass verschiedene Flexibilitäten teilweise dem EVU nicht gemeldet wurden (oder erst nach Rücksprache mit dem Eigentümer). Siehe auch Kapitel 4.8.2.
- Verbesserung des Lastmanagement durch Gruppierung von Boilern nach den Ladezeiten und durch neue Rundsteuerungs-Gruppeneinteilungen. Siehe auch Kapitel 3.3.
- Meldungen von Anomalien (Service zur Detektion). Verschiedene Installationsfehler konnten detektiert und behoben werden. Bei einem Gebäude war die Batterie mit dem PVA-Zähler verbunden. Der Lastgang zeigte eine PV-Produktion während der Nacht.
- Bereitstellung des virtuellen PV-Lastganges für das Energiemanagement. Der virtuelle PV-Lastgang beinhaltet auch den ungemessenen Eigenverbrauch. Daraus konnte der totale Verbrauch im Verteilnetz und für die Bilanzierung wichtige Lastgänge berechnet werden.
- Entwicklung eines neuen Flexibilitätsmodells für Ladestationen. Die Auswertung der Lastgänge von Trafostationen und privaten Ladestationen hat ergeben, dass zwischen 17 – 21 Uhr Überlastungen absehbar sind. Mit einem speziellen Flexibilitätsmodell für Ladestationen wurde ein Pilotversuch gestartet.
- Gezielte Erzeugung virtueller Lastgänge für PVA, Wärmepumpen, Boiler, Ladestationen sowie Prognosen einzelner Flexibilitäten.
- Analyse von Flexibilitäten, die über den Winter ausgeschaltet sind (z.B., wenn die Warmwasseraufbereitung im Winter via Ölheizung erfolgt, d.h. der Boiler wird nur während des Sommers betrieben).
- Abschätzung der Flexibilitätspotentiale in Relation zur Jahreszeit (Monat). Lastgang pro Flexibilität in den Wintermonaten (Nov-März) und im Sommer.
- Neue Flexibilitäts-Tarifmodelle (Konzept-Ideen). Beispiel: Für eine Flexibilität wird eine höhere Entschädigung ausgerichtet, wenn sie während den Peak-Zeiten für maximal zwei Stunden (Wärmepumpe) ausgeschaltet werden kann.

5 Schlussfolgerungen und Fazit

Der Boiler-Workflow wurde um einen Stage erweitert, der zusätzliche Metadaten wie Leistungsaufnahme, Einschaltzeitpunkt, Anzahl Schaltzyklen, durchschnittliche Einschaltzeit, maximale Einschaltzeit pro Boiler-Messpunkt eruiert. Anhand dieser Metadaten wurden die Boiler-Gruppen nach der mittleren Einschaltzeit neu gruppiert. Mit dieser Massnahme kann die Rundsteuerung die einzelnen Gruppen gezielter einsetzen.

Die Disaggregation der privaten Ladestationen-Messpunkte hat ergeben, dass die meisten Ladevorgänge werktags zwischen 17 und 23 Uhr mit einer mittleren Ladezeit von 2 Stunden erfolgen. Dieser Trend wird sich in Zukunft noch verstärken und überschneidet sich genau mit den heutigen Lastspitzenmaximum von 18 bis 21 Uhr. Mit einem Flexibilitätsmodell, dass Kunden belohnt, die nicht zwischen 17 und 21 Uhr laden, könnte ein wichtiger Beitrag zur Lastspitzenreduktion in den Abendstunden erfolgen und reduziert den vorzeitigen Ausbau von Transformatorstationen.

Hinsichtlich der Wärmebedarfsvorhersagen lieferten erste Validierungsverfahren erfreuliche Resultate, wobei die positiven Effekte der Aggregation mehrere Datenpunkte nachgewiesen werden konnte. Zudem wurden problematische Ausgangslagen hinsichtlich Wettersituation und Trainingsdaten erkannt, für welche die Methodik nun spezifisch adaptiert werden kann. Für die Gesamtenergie- sowie Boiler-Vorhersagen erwies sich die entwickelte Methode als zuverlässig genug für den Einsatz im Feldtest.

Einen sehr positiven Effekt zur Lastspitzenreduktion von 18 bis 21 Uhr haben die im privaten Bereich eingesetzten Batterien. Leider wird die installierte Speicherkapazität auch in absehbarer Zukunft viel zu gering sein, um einen spürbaren Lastspitzen-Reduktionsbeitrag zu leisten.

Die Summierung der disaggregierten Wärmepumpen Lastgänge zeigt auf, dass in den Wintermonaten (Dezember bis Februar) während den Verbrauchsspitzenzeiten (18 bis 21 Uhr) die Wärmepumpen einen immer stärkeren Einfluss auf die Lastspitze haben. Bei Temperaturen unter 0 Grad ist ein grosser Teil der Wärmepumpen über längere Zeit im Einsatz. Mithilfe des entwickelten Flexibilitätslabels kann in diesem Fall das Potential einzelner Flexibilitäten besser verstanden, verglichen und damit genutzt werden.

Die Ansteuerung der Wärmepumpen via dem Smart Grid Ready Signal hat sich als aufwendiger als geplant herausgestellt. Aktuell ist es noch nicht möglich, dass die verschiedenen Wärmepumpen Hersteller einfach angesteuert werden können. Für den externen Zugriff auf die Wärmepumpen fehlen auch bei neueren Gebäuden oft die Kommunikationsanbindungen (siehe auch Kapitel 7.1). Hier wären internationale Standards wünschenswert.

Mithilfe der entwickelten Erkennungsalgorithmen konnten markante Differenzen zwischen den Angaben in den Anschlussgesuchen bzw. Installationsanzeigen und den realen Leistungswerten identifiziert werden. Die Gründe für die Abweichungen sind vielfältig. So ist beispielsweise bei Boilern oft nicht bekannt, ob der Anschluss 1 oder 3 phasig erfolgt ist. Die Dokumentation beim Austausch von Boilern oder Wärmepumpen mit veränderten Werten wird häufig nicht nachgeführt. Auch der Ersatz eines Boilers durch einen Wärmepumpenboiler wird häufig nicht gemeldet. Zudem sind die Installationsanzeigen von Boilern bis zu 40 Jahre alt. Ausserdem wurde festgestellt, dass Installationen für E-Ladestationen häufig nicht angezeigt werden.

Die Feldversuche haben ergeben, dass die Qualität der Disaggregation der Flexibilitäten (Wärmepumpen, Boiler, Ladestationen, Batterien) markant verbessert werden kann, wenn die PV-Produktion aus dem zu analysierenden Lastgang entfernt wird.

Durch die sich periodisch wiederholende automatisierte Identifikation und Datenanalyse kann sicherstellt werden, dass der dokumentierte Datenbestand jederzeit den aktuellen realen Gegebenheiten möglichst nahekommt und sich das Gesamtsystem an Veränderungen (z. B. durch Ausbau PV und E-Ladeinfrastruktur oder Austausch von auf fossilen Brennstoffen basierende Heizungen durch Wärmepumpen) laufend anpassen kann.



6 Ausblick und zukünftige Umsetzung

Im GIASES-Projekt wurden die technischen Voraussetzungen für die Nutzung von Flexibilitäten geschaffen und in einer realen Netzumgebung implementiert und getestet. Um das volle Potential der Flexibilitäten für eine sinnvolle Lastverschiebung – und damit eine Reduzierung des Bedarfs an Netzausbau – auszuschöpfen, bedarf es auch der Einbeziehung der Eigentümer der Flexibilitäten.

Um dies zukünftig umsetzen zu können wurde deshalb im Rahmen der BFE Ausschreibung P+D Stromnetz 2023 von der Hochschule Luzern, der ASGAL Informatik GmbH und den Technischen Betrieben Vilters-Wangs ein Projektantrag mit dem Namen EkoFlex (Endkundenoptimiertes Flexibilitätsmanagement) gestellt. Als logische Weiterentwicklung sollen ab 2024 im EkoFlex-Projekt verschiedene Geschäftsmodelle unter Einbezug der Eigentümer definiert und evaluiert werden, um den grösstmöglichen Nutzen zur Entlastung der Netze zu erzielen. Mithilfe des im GIASES-Projekt implementierten Kundenportals mit aktuell über 440 Nutzenden soll die Kundeninteraktion realisiert werden. Durch aktive Freigabe von Kunden-Flexibilitäten werden verschiedene Geschäftsmodelle getestet, um eine optimale Nutzung zu ermöglichen.

Hauptziel ist die Demonstration und Umsetzung eines multifaktoriell optimierten Flexibilitätsmanagements. Durch Einbeziehung und Abgleich der EVU-Interessen, der Kundenakzeptanz und des -verhaltens hinsichtlich netzdienlicher Bereitstellung von Flexibilitäten soll die Reduktion von Lastspitzen und somit der Bedarf an Netzverstärkung im grösstmöglichen Ausmass reduziert werden. Dies umfasst im Einzelnen folgende Ziele:

- Erweiterung des bestehenden Kundenportals für die aktive Bereitstellung von Flexibilitäten sowie die Visualisierung der tatsächlichen Nutzung der bereitgestellten Flexibilitäten
- Entwicklung von Entschädigungsmodellen für die Bereitstellung von Flexibilitätsdiensten durch Endkunden unter Berücksichtigung der tatsächlichen Nutzung
- Entkopplung der Tarifmodelle von neuen Modellen zur Flexibilitätsentschädigung
- Aufbau und Testen einer Methodik, um Flexibilitäten (vor allem Wärmepumpen) nutzbar zu machen durch koordiniertes Schalten von Systemen von Endkunden
- Demonstration der Zugriffsmöglichkeit auf das Flexibilitätspotentials durch den Einsatz der in GIASES und NILM4BAL entwickelten Verfahren
- Analyse der Kosteneinsparmöglichkeit (Energieverkauf, Spitzenlastkompensation, Kostenersparnis Netzausbau) und Energieeinsparmöglichkeiten
- Integration von MLOps zur Schaffung eines stabilen und effizienten Systems für den kompletten ML-Entwicklungsprozesse, um die notwendige fortlaufende Optimierung, Bereitstellung, Aktualisierung und Validierung der Algorithmen bzw. ML-Modelle zu ermöglichen. Hierbei ist ein weiteres wichtiges Ziel die Qualitätssicherung, sowohl hinsichtlich der Modellperformance als auch hinsichtlich der Datensicherheit und des Datenschutzes.
- Bestimmung von Faktoren, welche die Akzeptanz zur Nutzung von Flexibilitäten beeinflussen. Dabei sollen die Partizipationsmöglichkeiten der diversen Nutzergruppen berücksichtigt werden und die Wirksamkeit der Massnahmen aus Sicht der Akteure evaluiert werden.

Mit der zukünftigen Umsetzung sollen folgende Fragestellungen beantwortet werden:

- Welche finanziellen und energetischen Einsparmöglichkeiten bieten die vorgeschlagenen Flexibilitätsverfahren für die unterschiedlichen Akteure?
- Wie muss die Erweiterung des Portals gestaltet werden, damit die Endkunden mit möglichst geringem Aufwand interagieren können (Usability)?
- Lassen sich die erwarteten/abgeschätzten Flexibilitätspotentiale in realen Umgebungen vollumfänglich nutzen? Welche Hardware/Konfigurationsanpassungen sind zusätzlich notwendig, um das Optimum zu erreichen?

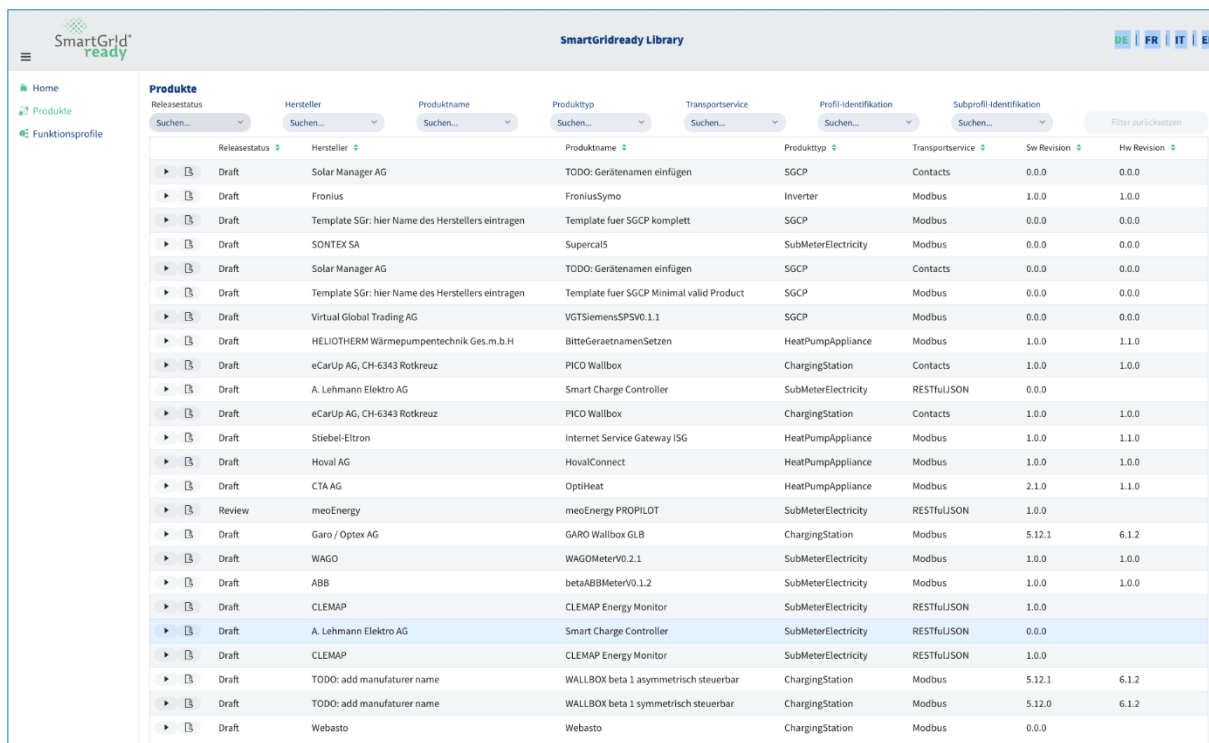


- Wie stabil lässt sich eine Lösung betreiben? Fallen Flexibilitätssysteme weg durch Anpassungen der Endkunden (bewusste oder unbewusste Manipulationen an den Steuerungssystemen, z.B. vergessene Smart Grid Ready Datenleitungen bei der Konfiguration durch Installateure)?
- Wie lassen sich die verschiedenen Nutzergruppen (Consumer, Prosumer / ZEVs, Industrie-, Gewerbebetriebe) in Bezug auf Einstellung, Motivation und Akzeptanz unterscheiden und charakterisieren? Welche tragfähigen Cluster lassen sich aus den unterschiedlichen Nutzertypen bilden und differenzieren?
- Welche Faktoren in den Botschaften und der Kommunikationsgestaltung beeinflussen die Bewertung und Akzeptanz von Flexibilitätsmodellen?
- Wie beeinflussen Motivation und Akzeptanz die Realisierbarkeit der Lösung? Wie können die Erkenntnisse zur Akzeptanz und tatsächlichem Verhalten in die Entwicklung zielführender Geschäftsmodelle und Kommunikationskonzepte zur Lastenverschiebung von Flexibilität integriert und umgesetzt werden?

7 Nationale und internationale Zusammenarbeit

7.1 SmartGridready

Hinsichtlich der Ansteuerung und Kontrolle von Flexibilitäten via SmartGridready - insbesondere für Wärmepumpen - gab es im Laufe des GIASES-Projekts Gespräche mit dem SmartGridReady-Verein. Zuletzt wurde in einem Meeting Anfang Oktober 2023 der Status bezüglich der Standardisierung der Schnittstellen diskutiert. Die Methode zur Erreichung der Standardisierung basiert auf einem objektorientierten Ansatz in Kombination mit individuellen XML-Templates zur Integration der diversen Hersteller und deren Produkte. Zwar konnten bei dem Bestreben die relevanten Protokolle technologieübergreifend abzugleichen Fortschritte erzielt werden, allerdings befinden sich die Bestrebungen Stand 10/23 noch im Draft- bzw. Review-Status und sind derzeit noch nicht oder nicht vollständig implementiert.



Releasestatus	Hersteller	Produktname	Produkttyp	Transportservice	Profil-Identifikation	Subprofil-Identifikation	Sw Revision	HW Revision
Draft	Solar Manager AG	TODO: Gerätenamen einfügen	SGCP	Contacts	0.0.0	0.0.0		
Draft	Fronius	FroniusSymo	Inverter	Modbus	1.0.0	1.0.0		
Draft	Template SGr: hier Name des Herstellers eintragen	Template fuer SGCP komplett	SGCP	Modbus	0.0.0	0.0.0		
Draft	SONTEX SA	Supercal5	SubMeterElectricity	Modbus	0.0.0	0.0.0		
Draft	Solar Manager AG	TODO: Gerätenamen einfügen	SGCP	Contacts	0.0.0	0.0.0		
Draft	Template SGr: hier Name des Herstellers eintragen	Template fuer SGCP Minimal valid Product	SGCP	Modbus	0.0.0	0.0.0		
Draft	Virtual Global Trading AG	VGT SiemensSPSV0.1.1	SGCP	Modbus	0.0.0	0.0.0		
Draft	HELIO THERM Wärmepumpentechnik Ges.m.b.H	BitteGerätenamenSetzen	HeatPumpAppliance	Modbus	1.0.0	1.1.0		
Draft	eCarUp AG, CH-6343 Rotkreuz	PICO Wallbox	ChargingStation	Contacts	1.0.0	1.0.0		
Draft	A. Lehmann Elektro AG	Smart Charge Controller	SubMeterElectricity	RESTfulJSON	0.0.0			
Draft	eCarUp AG, CH-6343 Rotkreuz	PICO Wallbox	ChargingStation	Contacts	1.0.0	1.0.0		
Draft	Stiebel-Eltron	Internet Service Gateway ISG	HeatPumpAppliance	Modbus	1.0.0	1.1.0		
Draft	Hoval AG	HovalConnect	HeatPumpAppliance	Modbus	1.0.0	1.0.0		
Draft	CTA AG	OptiHeat	HeatPumpAppliance	Modbus	2.1.0	1.1.0		
Review	meoEnergy	meoEnergy PROPILOT	SubMeterElectricity	RESTfulJSON	1.0.0			
Draft	Garol / Optex AG	GAROL Wallbox GLB	ChargingStation	Modbus	5.12.1	6.1.2		
Draft	WAGO	WAGOMeterV0.2.1	SubMeterElectricity	Modbus	1.0.0	1.0.0		
Draft	ABB	betaABBMeterV0.1.2	SubMeterElectricity	Modbus	1.0.0	1.0.0		
Draft	CLEMAP	CLEMAP Energy Monitor	SubMeterElectricity	RESTfulJSON	1.0.0			
Draft	A. Lehmann Elektro AG	Smart Charge Controller	SubMeterElectricity	RESTfulJSON	0.0.0			
Draft	CLEMAP	CLEMAP Energy Monitor	SubMeterElectricity	RESTfulJSON	1.0.0			
Draft	TODO: add manufacturer name	WALLBOX beta 1 asymmetrisch steuerbar	ChargingStation	Modbus	5.12.1	6.1.2		
Draft	TODO: add manufacturer name	WALLBOX beta 1 symmetrisch steuerbar	ChargingStation	Modbus	5.12.0	6.1.2		
Draft	Webasto	Webasto	ChargingStation	Modbus	0.0.0			

Abbildung 47: SmartGridready Library – Releasestatus Produkte (Stand 05.10.23)

Der aktuelle Stand kann der SmartGridready Library auf der Webseite des SmartGridready Vereins entnommen werden [14].

7.2 ENFLATE

Das europäische Horizon-Projekt ENFLATE [15] hat das Ziel mit einer Plattform für den Handel mit Flexibilitäten einen wichtigen Beitrag hin zur Klimaneutralität zu leisten. Mit dem ENFLATE-Projekt gab es Gespräche, um Synergieeffekte bezüglich der Disaggregation zu diskutieren. Insbesondere wurde im weiteren Verlauf erörtert, inwieweit für andere EVUs die Erkenntnisse aus dem GIASES Projekt für die Erkennung und Disaggregation von E-Ladestationen hilfreich sein können.



7.3 SWEET – PATHFNDR / EDGE

Die Erkenntnisse aus GIASES fliessen im Austausch auch in die SWEET-Projekte PATHFNDR [16] und EDGE [17] ein. In PATHFNDR untersucht ein Konsortium von Schweizer und Europäischen Forschungspartnern die optimale Integration von Flexibilitäten und die Sektorenkopplung. Die Modelle arbeiten dabei oft auf nationaler Ebene und untersuchen welche Flexibilitäten jeweils auf unterschiedlichen Aggregationsstufen (Subnetz, Gemeinde, Region) verfügbar gemacht werden müssten. GIASES liefert hierzu Verfahren, um diese Grössen basierend auf Messdaten zu schätzen respektive für die Testgebiete erste Abschätzungen für diese Potentiale zu ermöglichen. Durch die Teilnahme der Projektpartner in diesen Projekten kann so ein steter Austausch mit den Modellierungspartnern in PATHFNDR stattfinden, der einerseits nationale Wünsche und andererseits regional realisierbare Potentiale abgleicht.

In SWEET EDGE sollen Wege gefunden werden den Anteil lokal erzeugter erneuerbaren Energien zu erhöhen. In Ihrem Beitrag entwickelt HSLU das Empfehlungswerkzeug "Recommender tool", welche Gemeinden den Einfluss unterschiedlicher Entwicklungsszenarien auf Ihre Energiesysteme aufzeigt. Dabei können insbesondere auch Gebäude, Quartiere oder grössere Gebiete identifiziert werden, welche geeignet oder nötig sind, um Flexibilitäten zu nutzen. Es findet daher ein Zusammenspiel statt zwischen der Identifizierung von interessanten Gebieten mit dem Recommender Tool und der Quantifizierung der Flexibilitäten durch das Verfahren von GIASES. Denn Resultate von GIASES helfen dabei, die realen Beiträge von beispielsweise Wärmepumpensystemen verlässlicher aufzuzeigen, Gemeinden und lokale Energieversorgende auf Flexibilitätpotenziale aufmerksam zu machen und genauere Schätzungen dieser Potentiale zu erzielen.

8 Anhang

8.1 Literaturverzeichnis

- [1] „NILM4Bal - Non-Intrusive Load-Monitoring für Last- und Lastspitzenmanagement - Grunddaten“. [Online]. Verfügbar unter: <https://www.aramis.admin.ch/Grunddaten/?ProjectID=43330>
- [2] N. Batra u. a., „NILMTK: An Open Source Toolkit for Non-intrusive Load Monitoring“. doi: 10.1145/2602044.2602051.
- [3] „NILMTK: Non-Intrusive Load Monitoring Toolkit“. nilmtk. [Online]. Verfügbar unter: <https://github.com/nilmtk/nilmtk>
- [4] „NILM METADATA“. nilmtk. [Online]. Verfügbar unter: https://github.com/nilmtk/nilm_metadata
- [5] „Welcome to NILM Metadata’s documentation! — NILM Metadata 0.2.0 documentation“. [Online]. Verfügbar unter: <https://nilm-metadata.readthedocs.io/en/latest/>
- [6] „The HDF5® Library & File Format“, The HDF Group. [Online]. Verfügbar unter: <https://www.hdfgroup.org/solutions/hdf5/>
- [7] „Project Jupyter“. [Online]. Verfügbar unter: <https://jupyter.org>
- [8] „MLflow - A platform for the machine learning lifecycle“, MLflow. [Online]. Verfügbar unter: <https://mlflow.org/>
- [9] „Module: tf.keras | TensorFlow v2.10.0“. [Online]. Verfügbar unter: https://www.tensorflow.org/api_docs/python/tf/keras
- [10] A. Harell, S. Makonin, und I. V. Bajić, „Wavenilm: A causal neural network for power disaggregation from the complex power signal“. arXiv. doi: 10.48550/arXiv.1902.08736.
- [11] „Börsenstrompreise | Energy-Charts“. [Online]. Verfügbar unter: https://www.energy-charts.info/charts/price_spot_market/chart.htm?l=de&c=CH&week=05&legendItems=01111000000
- [12] E. Vilters-Wangs, „Kanton St.Gallen Amt für Wasser und Energie“. [Online]. Verfügbar unter: https://www.sg.ch/content/dam/sgch/umwelt-natur/energie/energiedaten/energiedaten-2018/Vilters-Wangs_Energiedaten_2018.pdf
- [13] „2021-03-08_EBP_CH_EmobSzen_PKW_2021.pdf“. [Online]. Verfügbar unter: https://www.ebp.ch/sites/default/files/2021-03/2021-03-08_EBP_CH_EmobSzen_PKW_2021.pdf
- [14] „Home - SmartGridready Library“. [Online]. Verfügbar unter: <https://library.smartgridready.ch/>
- [15] „ENFLATE: ENabling FLexibility provision by all Actors and sectors through markets and digital TEchnologies“, Hochschule-Luzern. [Online]. Verfügbar unter: <https://www.hslu.ch/de-ch/hochschule-luzern/forschung/projekte/detail/?pid=6216>
- [16] „Home - SWEET PATHFNDR Project“. [Online]. Verfügbar unter: <https://sweet-pathfndr.ch/>
- [17] „Homepage - SWEET EDGE“. [Online]. Verfügbar unter: <https://www.sweet-edge.ch/de/home>

8.2 Abbildungsverzeichnis

Abbildung 1: Übersicht Workflow Smart Energy System (SES)	10
Abbildung 2: Virtueller Lastgang aller disaggregierten Wärmepumpen.....	10
Abbildung 3: Virtueller Lastgang aller PV-Anlagen im Verteilnetz	11
Abbildung 4: Web-Plattform GIASES Smart Energy System.....	11
Abbildung 5: Analyse Auswertung Flexibilitäten (Beispiel Wärmepumpen)	12
Abbildung 6: Analyse Auswertung Flexibilitäten (Beispiel Batterien).....	13
Abbildung 7: Auswahl der Disaggregations-Modelle	13
Abbildung 8: Wohnungs-Lastgang.....	14
Abbildung 9: Disaggregierte Ladestation (blaue Linie)	14
Abbildung 10: Beispiel Datenselektion für ein MFH mittels nilmtk-Toolkit	16
Abbildung 11 Gruppierung von Boilern nach den detektierten Metadaten (Beispiel: Durchschnittliche Ladezeit)	16
Abbildung 12: Einzelplots Disaggregation Wärmepumpe.....	20
Abbildung 13: Input-Lastgang (rot), PV- Disaggregation (dunkelgrün)	20
Abbildung 14: Ground Truth (hellgrün), PV-Disaggregation (dunkelgrün).....	20
Abbildung 15: Input-Lastgang (rot), PV- Disaggregation (dunkelgrün), Verbrauch-Lastgang (blau)	21
Abbildung 16: Lastgang E-Ladestation	22
Abbildung 17 EFH mit Batterie, PVA und Wärmepumpe.....	22
Abbildung 18: Ladestationen, Hauptladezeiten von privaten E-Fahrzeugen	25
Abbildung 19: Mengengerüst der Messpunkte	26
Abbildung 20: Confusion Matrix Gerätetyperkennung Wärmepumpe	27
Abbildung 21 MFH Ground-Truth Lastgang (gelb) und Disaggregation (braun) des MFH-Netzübergabe Lastganges	28
Abbildung 22 EFH mit einer Batterie, PVA und Wärmepumpe.....	29
Abbildung 23: Beispielauswertung der Vorhersage einer Wärmepumpe für einen Tag.	30
Abbildung 24: NRMSE Werte der Wärmepumpen Komponente für individuelle MFH, ein aggregiertes Profil (agg_MFHs) sowie einen Mittelwert über alle MFH (mean_MFHs), dargestellt in einer aufsteigenden Reihenfolge.	30
Abbildung 25: NRMSE in Abhängigkeit der mittleren Tagestemperatur während der Vorhersage für die aggregierten MFH, den Mittelwert der MFH sowie ein atypisches MFH mit auffallend hohen NRMSE Werten	31
Abbildung 26: NRMSE von Wärmepumpen der einzelnen MFH (ohne Mittelwert und aggregiertem Datenset) über den gesamten Auswertungszeitraum für die jeweilige Kalenderwoche.	31
Abbildung 27: NRMSE Werte der Boiler Komponente für individuelle MFH, ein aggregiertes Profil (agg_MFHs) sowie einen Mittelwert über alle MFH (mean_MFHs), dargestellt in einer aufsteigenden Reihenfolge.....	32
Abbildung 28: Beispiel einer ungewöhnlichen Boiler-Spur mit entsprechender Schwierigkeit der Vorhersage.	33
Abbildung 29: NRMSE Werte vom Rest-Verbrauch für individuelle MFH, ein aggregiertes Profil (agg_MFHs) sowie einen Mittelwert über alle MFH (mean_MFHs), dargestellt in einer aufsteigenden Reihenfolge. Wenige grosse Ausreisser wurden aus Übersichtsgründen nicht dargestellt.....	34
Abbildung 30: Beispiel einer erfolgreichen Lastspitzen-Reduktion durch optimierten Schaltplan von 5 Wärmepumpen	35
Abbildung 31: Simulierte Peak Reduktion für 18 zufällig ausgewählte Tage.....	36
Abbildung 32: Ausschnitt der Spezifikation der Schnittstelle für Verbrauchsplanoptimierung.....	37
Abbildung 33: Übersicht der Zusammenhänge und Abhängigkeiten der Arbeitspakete 2-6 (siehe Kapitel 4.1 – 4.5).....	38
Abbildung 34: Beispiele der d-, s- und m-Profile einer Wärmepumpe, eines Boilers und einer EV-Ladestation	40



Abbildung 35: Profile der drei Häuser aus dem vorgestellten Beispiel	41
Abbildung 36: Tabelle der Flexibilitäts-Scores aus dem Beispiel	42
Abbildung 37: Optimierte Boiler-Gruppierung nach der mittleren Ladezeit	43
Abbildung 38 Day Ahead Preise in der Woche 5 2024 [11].....	43
Abbildung 39: TEM RC7000 Wärmepumpen Controller	44
Abbildung 40: Wärmepumpe mit einem dynamischen Zeitprogramm	44
Abbildung 41: Beispiel Anschlussgesuch Wärmepumpe.....	46
Abbildung 42: Beispiel Installationsanzeige Wärmepumpe und Boiler	47
Abbildung 43: Beispiel Installationsanzeige Smart-Meter Rollout	48
Abbildung 44: Lastgänge von Transformatoren mit einer Nennleistung von 400 kVA	49
Abbildung 45: Lastgang mit Rückspeisung PVA	49
Abbildung 46: Vergleichende Analyse Netzplanungsgrundsätze und Algorithmen gemäss EN 50160	50
Abbildung 47: SmartGridready Library – Releasestatus Produkte (Stand 05.10.23)	55
Abbildung 48: Ergebnisse 7-fold cross validation für die Disaggregation der Wärmepumpe	60



8.3 Ergebnisse 7-fold cross validation Disaggregation Wärmepumpe

```
Experiment Name : disagg-hp
Run ID         : bbf4dc7be8d64570bbce9db386fb9f60

TEST RESULTS FOR FOLD 1 - TRAIN: 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11 TEST: 12, 13
total_energy_error (kWh)      : -11.0795
rel_total_energy_error        : -0.1025
abs_total_energy_error (kWh)  : 42.0073
rel_abs_total_energy_error    : 0.3886
total_energy_gt (kWh)         : 108.0939
mean_absolute_error (kW)      : 1.7903

TEST RESULTS FOR FOLD 2 - TRAIN: 1, 2, 3, 4, 5, 6, 7, 8, 9, 12, 13 TEST: 10, 11
total_energy_error (kWh)      : -1.6507
rel_total_energy_error        : -0.0497
abs_total_energy_error (kWh)  : 10.8720
rel_abs_total_energy_error    : 0.3276
total_energy_gt (kWh)         : 33.1912
mean_absolute_error (kW)      : 0.4930

TEST RESULTS FOR FOLD 3 - TRAIN: 1, 2, 3, 4, 5, 6, 7, 10, 11, 12, 13 TEST: 8, 9
total_energy_error (kWh)      : 2.4481
rel_total_energy_error        : 0.0632
abs_total_energy_error (kWh)  : 13.9952
rel_abs_total_energy_error    : 0.3616
total_energy_gt (kWh)         : 38.7051
mean_absolute_error (kW)      : 0.6231

TEST RESULTS FOR FOLD 4 - TRAIN: 1, 2, 3, 4, 5, 8, 9, 10, 11, 12, 13 TEST: 6, 7
total_energy_error (kWh)      : 4.1051
rel_total_energy_error        : 0.0912
abs_total_energy_error (kWh)  : 12.9339
rel_abs_total_energy_error    : 0.2874
total_energy_gt (kWh)         : 45.0057
mean_absolute_error (kW)      : 0.5789

TEST RESULTS FOR FOLD 5 - TRAIN: 1, 2, 3, 6, 7, 8, 9, 10, 11, 12, 13 TEST: 4, 5
total_energy_error (kWh)      : -16.3509
rel_total_energy_error        : -0.2159
abs_total_energy_error (kWh)  : 23.4105
rel_abs_total_energy_error    : 0.3091
total_energy_gt (kWh)         : 75.7259
mean_absolute_error (kW)      : 1.0154

TEST RESULTS FOR FOLD 6 - TRAIN: 1, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13 TEST: 2, 3
total_energy_error (kWh)      : 0.2352
rel_total_energy_error        : 0.0039
abs_total_energy_error (kWh)  : 17.9340
rel_abs_total_energy_error    : 0.2962
total_energy_gt (kWh)         : 60.5453
mean_absolute_error (kW)      : 0.7872

TEST RESULTS FOR FOLD 7 - TRAIN: 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13 TEST: 1, 2
total_energy_error (kWh)      : 3.0254
rel_total_energy_error        : 0.0676
abs_total_energy_error (kWh)  : 17.0515
rel_abs_total_energy_error    : 0.3808
total_energy_gt (kWh)         : 44.7730
mean_absolute_error (kW)      : 0.7505

TEST RESULTS MEAN FOR ALL FOLDS:
total_energy_error (kWh)      : -2.7525
rel_total_energy_error        : -0.0203
abs_total_energy_error (kWh)  : 19.7435
rel_abs_total_energy_error    : 0.3359
total_energy_gt (kWh)         : 58.0057
mean_absolute_error (kW)      : 0.8626
```

Abbildung 48: Ergebnisse 7-fold cross validation für die Disaggregation der Wärmepumpe

Die Ergebnisse der einzelnen Folds zeigen, dass abhängig von der gewählten Aufteilung der Gebäude in Train und Test die Werte sehr unterschiedlich sein können, was auf ein heterogenes Verhalten der unterschiedlichen Wärmepumpen in den jeweiligen MFH zurückzuführen ist.