



Schweizerische Eidgenossenschaft
Confédération suisse
Confederazione Svizzera
Confederaziun svizra

Eidgenössisches Departement für
Umwelt, Verkehr, Energie und Kommunikation UVEK

Bundesamt für Energie BFE
Sektion Energieforschung und Cleantech

Schlussbericht vom 26.10.2020

Schlussbericht «SmartNIALMeter - Lastaufschlüsselung mit Smartmeter»





Datum: 26.10.2020

Ort: Bern

Subventionsgeberin:

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

Subventionsempfänger/innen:

Hochschule Luzern – Technik & Architektur, iHomeLab
Technikumstrasse 21, 6048 Horw
www.ihomelab.ch

Autor/in:

Guido Kniesel, HSLU T&A, guido.kniesel@hslu.ch
Thorsten Staake, Bits to Energy Lab, ETH Zürich, tstaake@ethz.ch

BFE-Projektbegleitung:

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

BFE-Vertragsnummer: SI/501561-01

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



Inhaltsverzeichnis

Inhaltsverzeichnis	3
Zusammenfassung	4
Résumé	5
Summary	6
1 Einleitung	7
1.1 Ausgangslage und Hintergrund.....	7
1.2 Motivation des Projektes	7
1.3 Projektziele.....	7
2 Vorgehen und Methode	8
2.1 Aufbau Dateninfrastruktur	8
2.2 Testbetrieb	11
2.3 Entwicklung On-/Off Detektor.....	11
2.4 Erkennungsalgorithmen	13
2.5 Projektanpassungen	16
2.6 Pilotbetrieb	17
2.7 User Front-End.....	17
3 Ergebnisse	19
3.1 Datenaufzeichnungen aus Test- und Pilotbetrieb	19
3.2 User Front-End.....	21
3.3 Erkennungsalgorithmen	23
3.4 Kundenumfrage.....	26
4 Erkenntnisse und Schlussfolgerungen	32
4.1 Herausforderungen bei den Datenaufzeichnungen	32
4.2 Erkennungsalgorithmen	33
5 Ausblick und zukünftige Umsetzung	34
5.1 Beurteilung der Hürden eines praxistauglichen Einsatzes von «non-intrusive Load-Monitoring-Ansätzen» in Haushalten	34
5.2 Zukünftige Umsetzung beim Projektpartner.....	38
6 Nationale und internationale Zusammenarbeit	39
7 Literaturverzeichnis	40
8 Abbildungsverzeichnis	41



Zusammenfassung

Ziel des Projektes SmartNIALMeter war es, auf der Basis von Smartmeter Daten und unter Einbezug moderner NIALM-basierten Verbrauchsanalysen (NIALM = **n**on-intrusive **a**ppliance **l**oad **m**onitoring) den Energieverbrauch nach wichtigen Geräten aufzuschlüsseln, dem Benutzer dies anzuzeigen und damit abzuklären, ob sich daraus eine Verhaltensänderung und damit ein Einsparpotential an elektrischer Energie ergibt. Dazu war es notwendig umfangreiche Messungen und Datenaufzeichnungen von Smartmeter Daten sowie elektrischen Verbrauchern durchzuführen. In einem Pilotbetrieb wurden in 24 Haushalten die Daten aufgezeichnet und mit Machine Learning Algorithmen Lastaufschlüsselungen (NIALM) durchgeführt. Ebenfalls wurde das Benutzerverhalten analysiert.

Eine wesentliche Erkenntnis des Projekts ist es, dass die implementierten und getesteten Algorithmen zur Lastaufschlüsselung nicht die Genauigkeit erreichen konnten, die für einen kommerziell verwertbaren Einsatz notwendig wären. Prinzipiell kann davon ausgegangen werden, dass eine massentaugliche Anwendung von präzisen und auf viele Geräte ausgerichtete NIALM-Verfahren für die kommenden fünf Jahre in Haushalten nicht zu erwarten ist. Hingegen dürften NIALM basierende Anwendungen, die sich auf die Erkennung weniger (oder sogar einzelner) großer Verbraucher beschränken, einfacher zu realisieren sein. Beispiele grosser Verbraucher sind Elektroautos, Wärmepumpen oder Boiler. Dazu zeigt eine wachsende Anzahl von Veröffentlichungen zu NIALM-Algorithmen vielversprechende neue Ansätze. Weiterhin konnten aus den Kundenumfragen die Erkenntnisse gewonnen werden, dass Ansätze wie ein Verbrauchs-Feedback dazu beitragen können, Hürden bezüglich Beratungsleistungen für Optimierungsmassnahmen abzubauen und insgesamt ein erhebliches Interesse sowie eine gute Zahlungsbereitschaft für datenbasierte Energiedienstleistungen besteht. Des Weiteren sollte beim Aufbau und Betrieb von Installationen und einer Infrastruktur für Datenaufzeichnungen beachtet werden, dass diese mit zahlreichen Herausforderungen behaftet sind und enorm zeitaufwendig sein können.



Résumé

L'objectif du projet SmartNIALMeter était d'estimer si le comportement des utilisateurs pouvait être influencé — et mener à une baisse de la consommation d'énergie — lorsque ces derniers ont accès de manière simple à la consommation de chacun de ses appareils. Pour que la ventilation des consommations selon le type d'appareil puisse être implémenté à bas coûts dans les ménages, l'objectif était de désagréger la consommation des appareils sur la base des données directement issues des compteurs intelligents à l'aide de méthodes d'analyses modernes basées sur le NIALM (NIALM = **n**on-**i**ntrusive **a**ppliance **l**oad **m**onitoring). L'enregistrement de nombreuses mesures de la consommation électrique des différents appareils ainsi que de données issues des compteurs intelligents ont été ainsi nécessaires : dans le cadre du projet pilote, les données de 24 ménages ont été enregistrées et la séparation des postes de consommations a été effectuée à l'aide des algorithmes NIALM. Le comportement des utilisateurs a également été étudié.

L'une des principales conclusions du projet est que les algorithmes mis en œuvre et testés pour la désagrégation des postes de consommation ne pouvaient pas atteindre la précision requise pour une utilisation commerciale. Au vu des difficultés rencontrées, notamment à cause des signatures variées des différents appareils rendant la reconnaissance d'un nombre large d'appareils très compliqué ainsi que du manque de précision observé, il est estimé qu'une application massive de méthodes NIALM dans les ménages est peu probable au cours des cinq prochaines années. Néanmoins, les applications basées sur le NIALM qui se limitent à la détection de quelques gros consommateurs (ou même d'un seul) devraient être plus faciles à mettre en œuvre. Les voitures électriques, les pompes à chaleur ou les chaudières sont des exemples de tels gros consommateurs. De nouvelles approches prometteuses utilisant les algorithmes NIALM de cette manière sont décrites dans un nombre croissant de publications scientifiques. En outre, des sondages menés auprès des clients ont montré que des approches telles que le retour d'information sur la consommation peuvent contribuer à lever les obstacles aux services de conseil pour les mesures d'optimisation et qu'il existe un intérêt et une volonté non négligeable de payer pour des services énergétiques basés sur l'utilisation de leurs données. Pour finir, il convient de garder à l'esprit que la mise en place d'une infrastructure d'enregistrement des données d'appareils électriques et l'analyse de ces données présentent de nombreux défis et peuvent prendre un temps considérable.



Summary

The aim of the SmartNIALMeter project was to break down energy consumption by important appliances on the basis of smart meter data and with the help of modern NIALM-based consumption analyses (NIALM = non-intrusive appliance load monitoring), to indicate this to the user and to clarify whether this results in a change in behaviour and thus a potential for saving electrical energy. For this purpose, it was necessary to carry out extensive measurements and data recordings of smart meter data and electrical consumers. In a pilot operation the data was recorded in 24 households and load disaggregation (NIALM) were carried out using machine learning algorithms. User behaviour was also analysed.

A major finding of the project is that the implemented and tested algorithms for load disaggregation could not achieve the accuracy required for commercial use. In principle, it can be assumed that a mass application of precise NIALM procedures, which are geared to many devices, is not to be expected in households for the next five years. On the other hand, NIALM-based applications, which are limited to the detection of a few (or even individual) large consumers, should be easier to implement. Examples of large consumers are electric cars, heat pumps or boilers. A growing number of publications on NIALM algorithms show promising new approaches. Furthermore, the customer surveys have shown that approaches such as consumption feedback can help to reduce barriers to consulting services for optimisation measures and that there is considerable interest and willingness to pay for data-based energy services. Furthermore, when setting up and operating installations and an infrastructure for data recording, it should be borne in mind that these are fraught with numerous challenges and can be extremely time-consuming.



1 Einleitung

1.1 Ausgangslage und Hintergrund

Die Autoren verschiedener Studien weisen ein Potential zur Energieeinsparung nach, wenn den Menschen der Energieverbrauch möglichst unmittelbar und detailliert angezeigt wird. Ziel dieses Projekts ist es, in einer Studie das Einsparpotential an elektrischer Energie zu prüfen, wenn der Energieverbrauch aufgeschlüsselt nach einigen wichtigen Geräten aufgezeigt wird.

Der Gesamtstromverbrauch pro Haushalt kann mit Hilfe eines Smart-Meters gemessen und dem Bewohner über ein Display in der Wohnung angezeigt werden. Um detailliertere Informationen zu erhalten gibt es auf dem Markt elektronische Zähler in Form von intelligenten Zwischensteckern (Smart-Plugs), mit denen der Stromverbrauch einzelner Geräte gemessen und an ein Web-basiertes Monitoring-System übermittelt werden kann. Dieser Ansatz ist jedoch aufwändig, da jedes darzustellende Gerät mit einem eigenen Zwischenstecker, welcher je nach Hersteller zwischen 40 und 120 CHF kostet, ausgerüstet werden muss. Als Alternative wird seit einigen Jahren der Ansatz der Lastaufschlüsselung untersucht. Dabei werden auf Basis einer Gesamtmessung, z.B. im Elektroverteilkasten der Wohnung, mit Hilfe von speziellen Algorithmen einzelne Verbraucher anhand ihrer elektrischen Signatur identifiziert und deren individueller Verbrauch aufgezeigt. Diese Signatur ist eine Art Fingerabdruck, den jedes Gerät beim Betrieb auf dem Stromnetz hinterlässt. Die entsprechenden Methoden zur Lastaufschlüsselung werden unter dem Begriff non-intrusive appliance load monitoring (NIALM) zusammengefasst.

Die Projektpartner Energie Thun und EKZ stellen im Rahmen ihrer Smart-Meter-Rollouts Testhaushalte für ein Pilotprojekt. NIALM-Algorithmen werten die Daten aus, welche die CII-Schnittstelle aus den Smart-Metern von Landis+Gyr ausgibt. Die Hochschule Luzern und das Bits to Energy Lab adaptieren bekannte NIALM-Algorithmen. Die Validierung erfolgt mit Sub-Metern von smart-me.

1.2 Motivation des Projektes

Private Haushalte können wesentlich dazu beitragen, die Ziele der Energiestrategie 2050 zu erreichen, indem die Bewohner und Bewohnerinnen sich energieeffizienter verhalten. Studien zeigen, dass ein Einsparpotential von bis zu 10 % realisierbar ist, wenn die Bewohner über Feedbacksysteme über ihren Stromverbrauch informiert werden [1]–[3]. Eine wichtige Erkenntnis ist dabei, dass das Einsparpotential umso höher ist, je detaillierter und zeitnaher der Bewohner über den aktuellen Stromverbrauch informiert wird. Zudem kann ein Feedbacksystem nur zu wesentlichen Einsparungen führen, wenn es die Informationen verständlich und ansprechend darstellt.

1.3 Projektziele

Das Projekt hat hauptsächlich zum Ziel, die Lastaufschlüsselung auf der Basis der Smart-Meter-Daten im Feld zu erproben. Dabei setzen wir eine einfache Version eines Feedbacksystems ein, welches den Testteilnehmern die detaillierten Verbrauchswerte in ihrem Haushalt zeigt. Die daraus gewonnenen Erkenntnisse bezüglich der Genauigkeit der Lastaufschlüsselung und der Akzeptanz seitens der Teilnehmer bilden die Grundlage für eine weitere Verbesserung des Feedbacksystems im Hinblick auf eine an das Projekt anschliessende Weiterentwicklung und Markteinführung.



2 Vorgehen und Methode

Das Projektziel war eine Lastaufschlüsselung unter realen Bedingungen in einem Feldtest durchzuführen. Dafür war es notwendig, Installationen bei Pilotteilnehmern durchzuführen und eine Dateninfrastruktur zur weiteren Verarbeitung aufzubauen. Für die Disaggregation der Daten mussten ML-Algorithmen entwickelt und getestet werden. Um den Erfolg des Projekts zu messen, wurde für die Pilotteilnehmer ein Feedback-System entwickelt (User Front-End) und die Rückmeldungen in einer Kundenbefragung ausgewertet und dokumentiert. Die Einzelheiten sind den folgenden Unterkapiteln zu entnehmen.

2.1 Aufbau Dateninfrastruktur

Um die Daten für das Training und die Validierung der NIALM-Algorithmen aufzeichnen und weiterverarbeiten zu können, ist der Aufbau einer Dateninfrastruktur notwendig. Hierfür nutzen wir die Cloud-Infrastruktur von Google und vom Zählerhersteller smart-me.

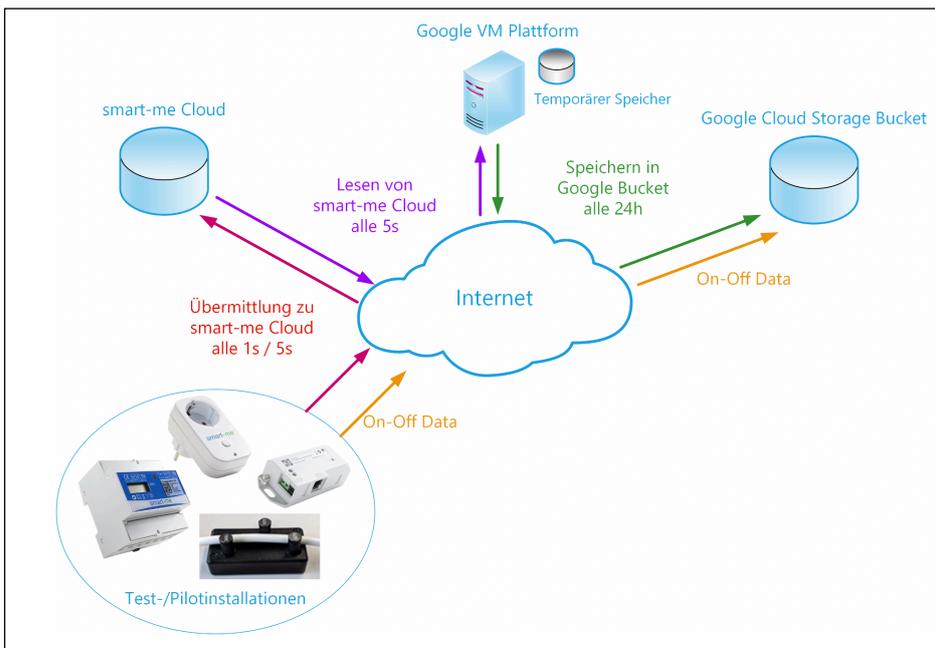


Abbildung 1: Dateninfrastruktur

In den Testhaushalten werden mit Submetern des Herstellers smart-me Wirk- und Scheinleistung gemessen und sekundlich an die smart-me Cloud gesendet. Die vom L+G Smartmeter gemessenen Werte werden vom smart-me L+G Modul alle 5 Sekunden an die smart-me Cloud übermittelt. Abbildung 2 zeigt exemplarische Beispiele der erfassten Messwerte.



```
smart-me 3-phase Meter:  
Die Datei YYYYMMDD_meterdata.csv enthält Zählerdaten wie unten dargestellt für jeweils 1 Tag und speichert folgende Momentanwerte:  
  
Date Time (UTC), ActivePower L1, ActivePower L2, ActivePower L3, ReactivePower L1, ReactivePower L2, ReactivePower L3  
...  
2018-02-20 06:20:01.013Z,4.139,1.498,0.016,1.0,1.0,1.0  
2018-02-20 06:20:05.994Z,4.142,1.49,0.016,1.0,1.0,1.0  
2018-02-20 06:20:10.810Z,4.15,1.488,0.016,1.0,1.0,1.0  
2018-02-20 06:20:15.831Z,4.151,1.48,0.016,1.0,1.0,1.0  
2018-02-20 06:20:20.788Z,4.137,1.492,0.016,1.0,1.0,1.0  
...  
  
smart-me Plug / smart-me Meter (single phase):  
Die Datei YYYYMMDD_meterdata.csv enthält Zählerdaten wie unten dargestellt für jeweils 1 Tag und speichert folgende Momentanwerte:  
  
Date Time (UTC), ActivePower, cosPhi  
...  
2018-02-20 11:04:39.847Z,7.2,0.49  
2018-02-20 11:04:45.989Z,455.45,0.604  
2018-02-20 11:04:51.122Z,1153.2,1.0  
2018-02-20 11:04:56.250Z,64.06,0.608  
2018-02-20 11:05:01.343Z,64.09,0.467  
...  
  
smart-me CII-Adapter und L+G E450 meter (3-phase):  
Die Datei YYYYMMDD_meterdata.csv enthält Zählerdaten wie unten dargestellt für jeweils 1 Tag und speichert folgende Momentanwerte:  
  
Date Time (UTC), Voltage L1, Voltage L2, Voltage L3, Current L1, Current L2, Current L3, cosPhi L1, cosPhi L2, cosPhi L3  
...  
2018-03-14 09:49:56.244Z,232.0,233.0,233.0,0.34,0.67,1.07,0.809,0.809,0.857  
2018-03-14 09:50:01.189Z,232.0,233.0,233.0,0.34,0.67,1.14,0.809,0.809,0.883  
2018-03-14 09:50:06.230Z,232.0,233.0,233.0,0.34,0.67,1.14,0.809,0.809,0.883  
2018-03-14 09:50:11.169Z,232.0,233.0,233.0,0.34,0.67,1.15,0.809,0.819,0.883  
...
```

Abbildung 2: Messdaten

Ein virtueller Linux-Rechner auf der Google VM Infrastruktur liest alle 5 Sekunden die Messdaten aller Submeter und Smartmeter in den Testhaushalten von der smart-me Cloud und speichert die Messwerte im Filesystem des virtuellen Rechners. Pro Meter und Tag wird ein *.csv File erstellt.

Nach Mitternacht werden die Messdaten des letzten Tages vom File System des Linux-Rechners auf einen Google-Cloud-Speicher kopiert und anschliessend überprüft. Für jedes *.csv File auf dem Google-Cloud-Speicher – also für jeden Zähler – wird geprüft, wie viele Messwerte fehlen oder ob doppelte Messeinträge vorhanden sind. Das Resultat dieser ersten Überprüfung wird täglich als Email an die Verantwortlichen verschickt.

Um NIALM-Algorithmen zu trainieren und zu testen, werden die Messdaten vom Google-Cloud-Speicher gelesen. Zur effizienten Speicherung und zum schnellen Abruf der Messdaten und der Ergebnisse aus der Lastaufschlüsselung ist eine Datenbank aufgesetzt. Abbildung 3 zeigt das dazugehörige Datenbankschema.

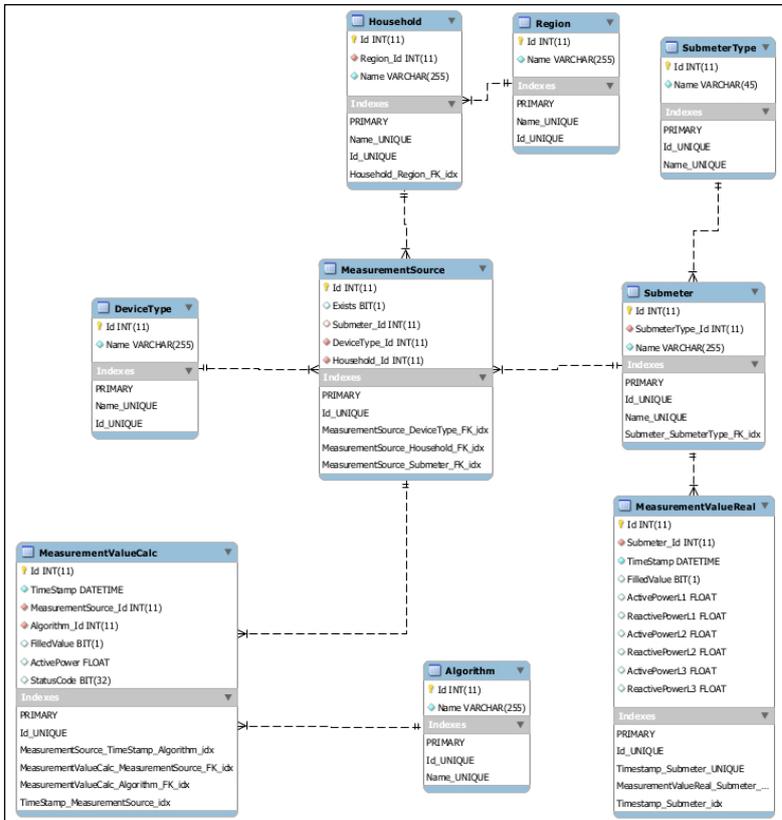


Abbildung 3: Datenbankschema

Für die Datenbank, das Pre-Processing, die Lastaufschlüsselung und den Webservice wurde eine auf Docker-Containern basierte Architektur entwickelt und implementiert (siehe Abbildung 4).

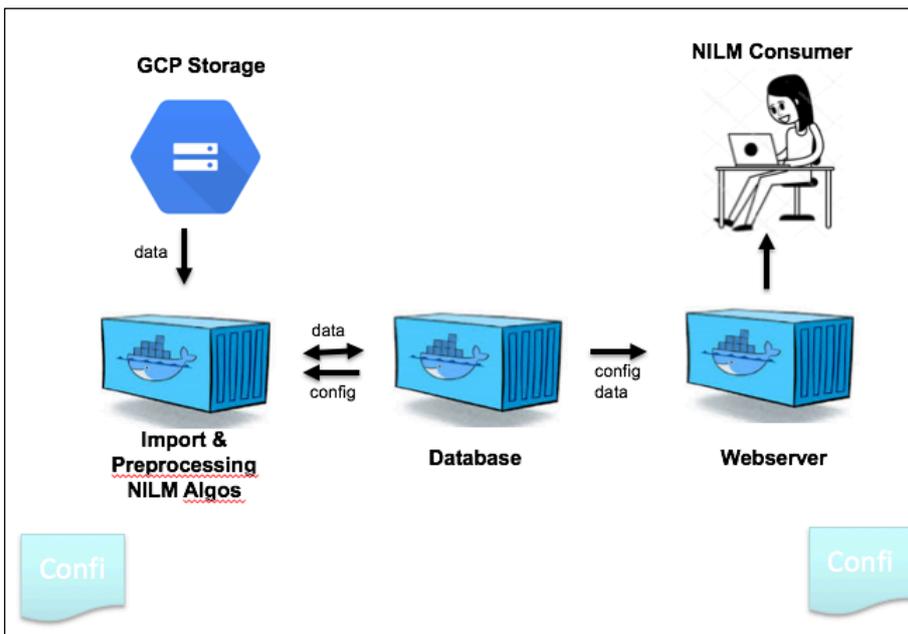


Abbildung 4: Docker-Architektur



2.2 Testbetrieb

In insgesamt 7 Haushalten haben wir smart-me Messgeräte und L+G Smartmeter mit smart-me L+G Modulen installiert. Dabei wurde insgesamt folgende Messinfrastruktur verbaut:

- 26 smart-me 3-Phasen-Zähler
- 19 smart-me Plugs
- 1 smart-me 1-Phasen-Zähler
- 7 smart-me L+G Module
- 7 L+G Smartmeter E450

Mit den installierten Messgeräten werden in 7 Testhaushalten folgende Verbraucher gemessen:

Verbraucher	Anzahl	1-phasig	3-phasig
Kochherd	7	0	7
Geschirrspüler	7	4	3
Waschmaschine	7	3	4
Kühlschrank	6	6	0
Backofen	6	2	4
Tumbler	6	3	3
Boiler	5	0	5
E-Auto Ladestation	2	0	2
Gefrierschrank	1	1	0

Abbildung 5: Gemessene Verbraucher in den Testhaushalten

2.3 Entwicklung On-/Off Detektor

Im Verlauf des Projekts wurde nach einer Möglichkeit gesucht, den Einschaltzustand eines Verbrauchers mit möglichst geringem Aufwand zu erfassen. Unter Einschaltzustand wird hier zwischen an, Standby und Aus unterschieden. Als einfachste Möglichkeit wurde hier die Installation eines Power Plug evaluiert. Diese Lösung besticht durch ihre Einfachheit und guter Verfügbarkeit durch zahlreiche kommerzielle Produkte. Ein wesentlicher Nachteil liegt jedoch darin, dass für die Installation die Netzkabel der zu untersuchenden Verbraucher erreichbar sein müssen. Dieser Umstand ist vor allen dann nicht gegeben, wenn es sich um Verbraucher wie Abwaschmaschinen, Kühlschränke oder Öfen handelt, welche meist fest in eine Küchengaritur eingebaut sind. Die Netzkabel sind hier hinter Abdeckungen verlegt, wodurch der Zugang sowie Platzbedarf wesentlich limitiert ist. Auch können mit einem Power Plug keine mehrphasig angeschlossenen Verbraucher gemessen werden.

Um in diesen Fällen trotzdem eine Abschätzung des Einschaltzustandes zu erhalten, wurde nach einer alternativen Lösung gesucht. Da keine kommerziellen Sensoren gefunden werden konnten, welche die Leistungsaufnahme kontaktlos erfassen können, wurde ein eigener dedizierter Sensor entwickelt.



Funktionsprinzip

Eine normale Strommesszange integriert das magnetische Wechselfeld um einen Leiter. Da der magnetische Fluss sich hierbei proportional zum Strom im Leiter verhält, kann einfach auf die Scheinleistung eines Verbrauchers geschlossen werden. Dieses Messprinzip funktioniert jedoch nur, wenn entweder Phase oder Neutralleiter separat gemessen werden da sich sonst die Magnetfelder von Hin- und Rückleiter gegenseitig aufheben.

Um dieses Problem zu umgehen und ein Auftrennen der Netzkabel zu verhindern, wurde ein neues Messprinzip untersucht. Das evaluierte Sensorprinzip basiert auf der Messung des Wechselstrom-Magnetfelds an der Kabelummantelung an drei verschiedenen Stellen. Wegen konstruktionsbedingten Asymmetrien heben sich die Magnetfelder von Hin- und Rückleiter nahe dem Kabel nicht auf. Dadurch ist es möglich, an der Oberfläche des Kabels ein Magnetfeld proportional zur Stromstärke zu messen. Durch die separate Messung des magnetischen Flusses an drei Stellen am Kabel wird sichergestellt, dass mindestens an einer Stelle ein ausreichend hohes Magnetfeld detektiert werden kann. Da die genaue Orientierung der Leiter im Kabel bei der Installation nicht bekannt ist, wird nur das stärkste Magnetfeld aufgezeichnet.

Mit dem Sensor ist es nicht möglich, ohne Kalibrierung die absolute Leistungsaufnahme eines Verbrauchers zu messen. Jedoch können sehr gut Ein-/Ausschaltvorgänge und Betriebszustände erkannt werden.

Der fertige Sensor ist in Abbildung 6 zu sehen. Der Sensor besitzt eine Abmessung von 80 x 40 x 35 mm und verfügt über eine extrem stromsparende Kommunikationsschnittstelle auf Basis der Bluetooth Low Energie (BLE) Funktechnologie.

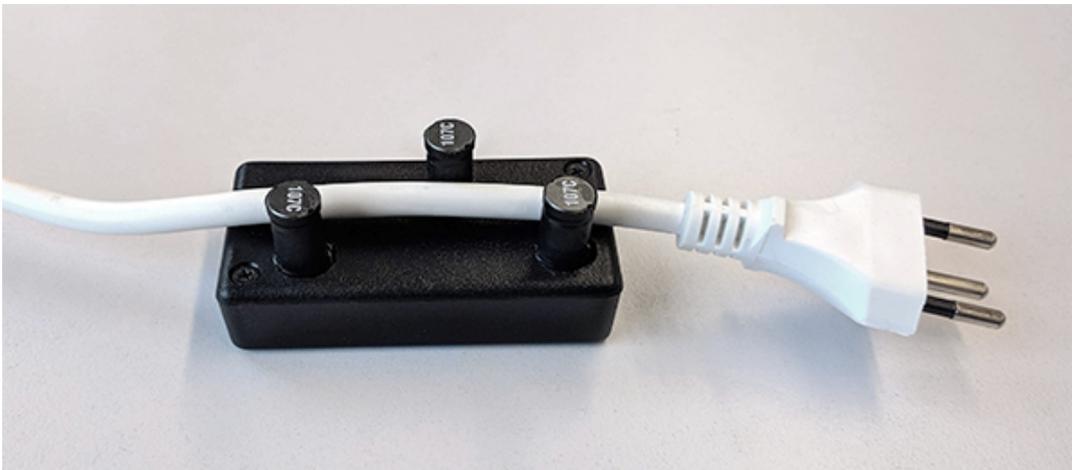


Abbildung 6: On-/Off-Detektor an einem Netzkabel

Validierung

Um das Funktionsprinzip zu validieren, wurden verschiedene Tests an realen Haushaltsgeräten durchgeführt. In Abbildung 7 und Abbildung 8 ist ein Vergleich der Rohdaten des On-/Off-Detektors mit einem Stromzähler bei zwei Haushaltsgeräten (Boiler & Waschmaschine) zu sehen. Wegen der höheren Abtastrate des On-/Off-Detektors sind auch Transienten mit höheren Frequenzen im Signal zu sehen.

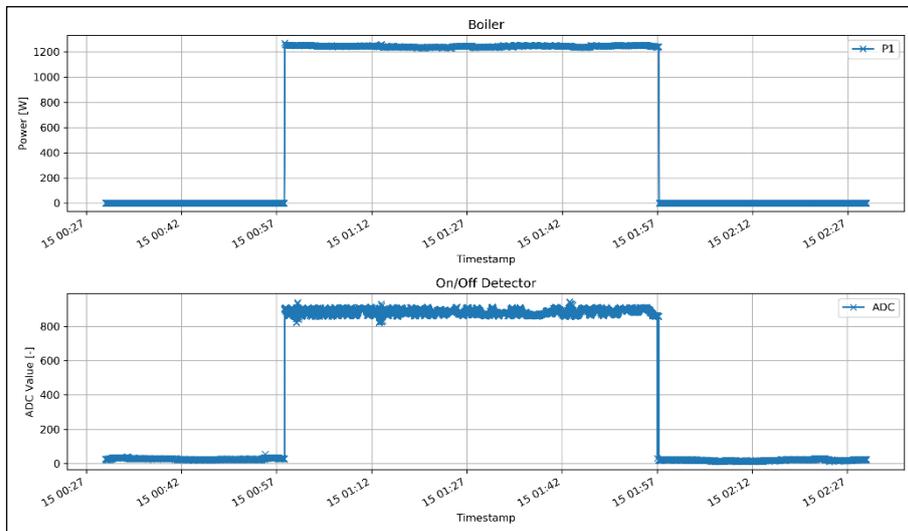


Abbildung 7: Rohdaten des On-/Off-Detektors an einem Boiler (unten) sowie Referenzmessung mittels smart-me 3-Phasen-Zähler (oben)

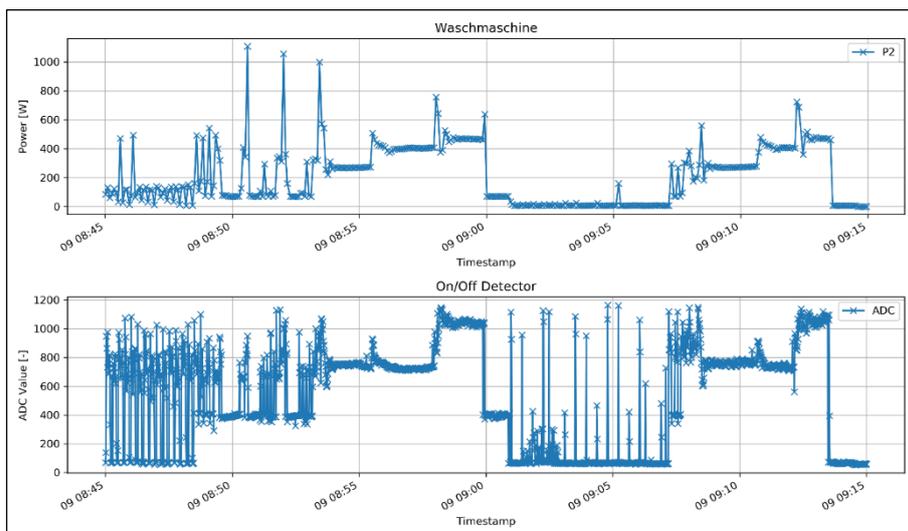


Abbildung 8: Rohdaten des On-/Off-Detektors an einer Waschmaschine (unten) sowie Referenzmessung mittels smart-me 3-Phasen-Zähler (oben)

2.4 Erkennungsalgorithmen

Im Rahmen von AP3 wurden folgende Arbeiten durchgeführt:

Nachvollziehen der Arbeiten von Kelly und Knottenbelt im Originalcode mit dem Deep Learning Framework Theano und Lasagne:

- Erste Prototyp-Version, auf der das Paper basiert [4]
- Zweite, überarbeitete Version [5]
- Evaluation der verwendeten Algorithmen
- Re-Implementierung des gewählten Algorithmus in TensorFlow
- Identifizierung von Optimierungsmöglichkeiten
- Evaluation



Als Grundlage diente die Arbeit von Kelly und Knottenbelt [6]. Für diese Arbeit wurde der UK-Dale-Datensatz [7] verwendet. Zuerst wurden die beiden Versionen nachvollzogen und die verwendeten Algorithmen verglichen. Folgende Parameter wurden dabei verwendet:

Zusammensetzung des Testdatensatzes UK-Dale:

- 5 Privathaushalte mit aufgezeichneten Daten über 1 bis 2 Jahre (Wirkleistung)
- 5 Verbraucher: washing machine / fridge / kettle / microwave / dish washer
- Sub-Meter: Sampling-Rate 6 Sekunden
- Mains: Sampling-Rate 1 Sekunde -> downsampling auf 6 Sekunden

Evaluation der Deep-Learning-Algorithmen:

- *Convolutional Neural Network (CNN) / Regression*: Da nur 3 Werte vorhergesagt werden (Start, Ende, Gesamtverbrauch, die in einem Rechteck dargestellt werden), ist die Tiefe der Informationen zu gering. Zudem ist es bei diesem Algorithmus nicht möglich, bereits während der Aktivierung der Appliance Vorhersagen zu machen.
- *Autoencoder*: Durch die Kompression und Dekompression in den neuronalen Schichten gehen für die Disaggregation wichtige Informationen verloren.
- *Recurrent Neural Network (RNN) / Long Short-Term Memory (LSTM)*: Dieser Algorithmus zeigte insgesamt über alle Verbraucher hinweg die besten Ergebnisse, da durch bidirektionale LSTM-Zellen, sowohl die Historie der Time-Series-Daten abgebildet wird, als auch zukünftige Datenpunkte während der Trainingsphase mit in den Lernmechanismus einfließen.

Neuimplementierung RNN / LSTM in TensorFlow

Das RNN / LSTM Netzwerk wurde mit einem modernen Deep Learning Framework (TensorFlow) neu implementiert. Lediglich für das Pre-Processing der Daten wurden Teile (Python-Code) aus der zweiten, überarbeiteten Version von Kelly verwendet.

Verwendete Netztopologie:

- Input (appliance activation timeframe)
- Bidirectional LSTMCell (N=128, use_peepholes=True, initializer=he_init)
- Bidirectional LSTMCell (N=128, use_peepholes=True, initializer=he_init)
- Dense Layer (N=128, activation function=TanH)
- Output (N=1, activation function=linear)

Im Gegensatz zur Kelly Implementierung wurde auf einen vorgeschalteten eindimensionalen CNN-Layer verzichtet, da dieser keine signifikanten Verbesserungen erzielen konnte und die Trainingszeiten nur unnötig erhöhte.

Für Training, Validierung und Test der Neuimplementierung wurden die beiden Geräte Waschmaschine und Kühlschrank des UK-Dale Datensatzes mit folgenden Parametern verwendet:

- Waschmaschine:
 - 3 Haushalte / 1.000 activations / timeframe 1024 * 6 sec (102 min)
 - Batchsize 16
 - Sequenzlänge 1024
 - 40.000 Epochen
 - Trainingszeit etwa 42 Stunden (GPU: NVIDIA Tesla K80)



- Kühlschrank:
 - 4 Haushalte / 20.000 activations / timeframe 512 * 6 sec (51 min)
 - Batchsize 16
 - Sequenzlänge 512
 - 20.000 Epochen
 - Trainingszeit etwa 17 Stunden (GPU: NVIDIA Tesla K80)

Training: 50% activations / 50% ohne activations; nur vollständige activations

Test mit unseen activations of known houses

Für jedes Gerät wurde ein eigenes Netzwerkmodell trainiert und in der Testphase die Disaggregation durchgeführt. Die folgenden beiden Abbildungen verdeutlichen den Vorgang:

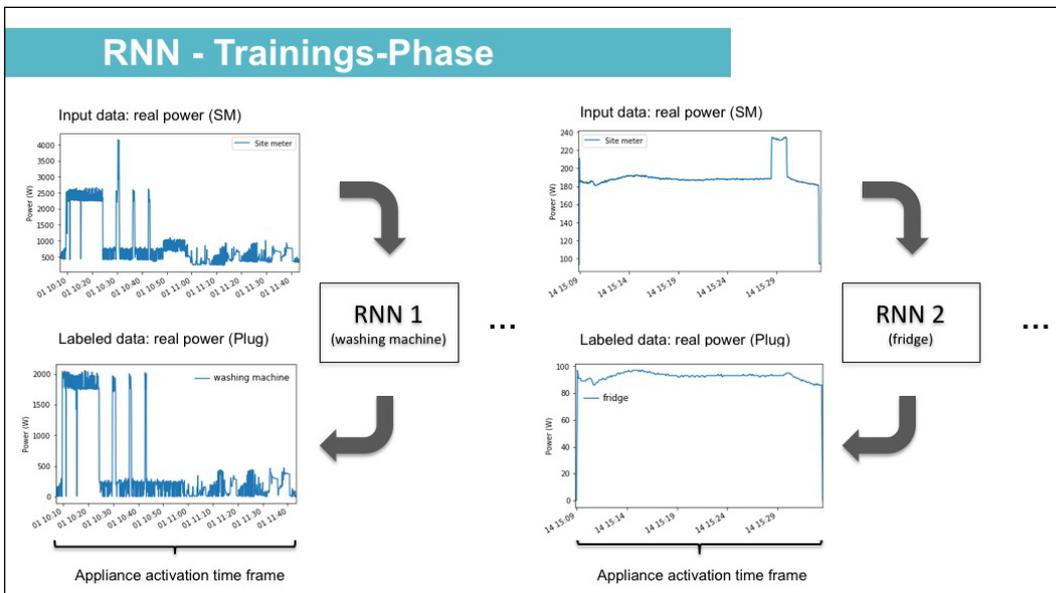


Abbildung 9: RNN Trainings-Phase

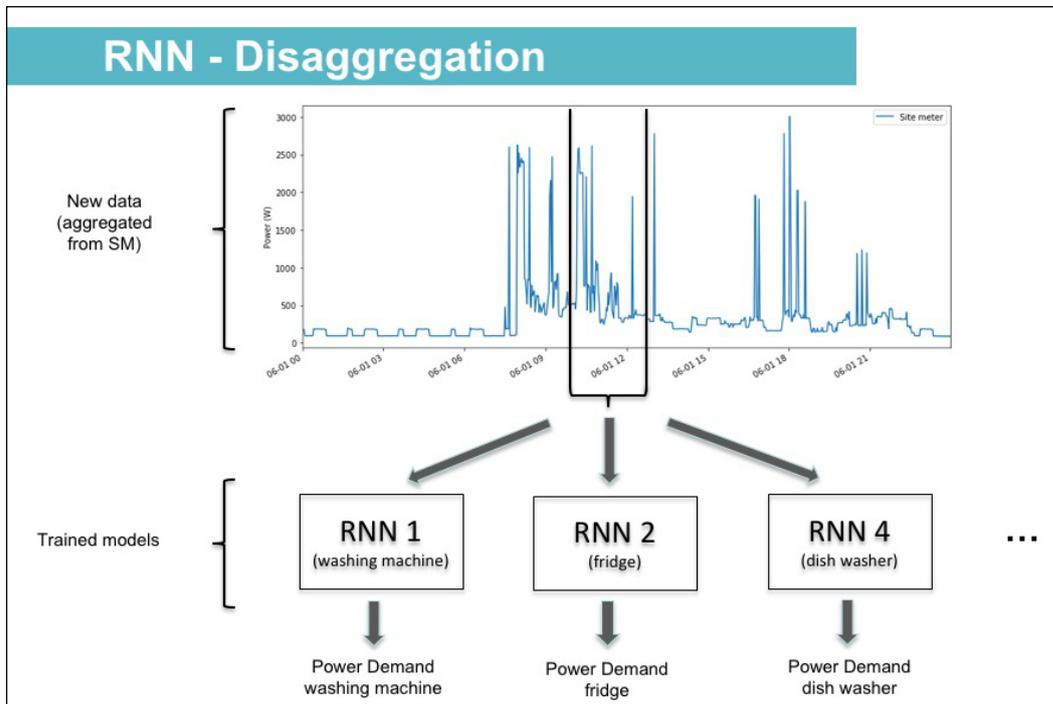


Abbildung 10: RNN Disaggregation

Die für den UK-Dale Datensatz verwendeten Algorithmen wurden im weiteren Verlauf des Projekts auf die erfassten Messdaten der Test- und Pilothaushalte angewendet und weiterentwickelt. Die erzielten Ergebnisse und Erkenntnisse sind den nachfolgenden Kapiteln zu entnehmen.

2.5 Projektanpassungen

Aufgrund der im folgenden aufgeführten Ursachen wurden im Laufe des Projekts Anpassungen vorgenommen, was eine Verlängerung der Projektlaufzeit nach sich zog.

Ursachen für Projektanpassungen

- Der Produktrelease der für das Projekt essentiellen smart-me L+G Module hat sich um mehrere Monate verzögert.
- Der Aufwand und damit auch die Dauer für die Akquisition von brauchbaren Trainings- und Verifikationsdaten wurde bei der Antragserstellung unterschätzt. Insbesondere der Aufbau einer zuverlässig funktionierenden Infrastruktur zur Datenaufzeichnung und Speicherung hat wesentlich mehr Zeit benötigt als geplant.
- Der anfänglich angedachte Algorithmus von Kelly und Knotenbelt zur Lastaufschlüsselung erreicht nicht die Genauigkeit, welche benötigt wird, um ein brauchbares Resultat zu erhalten. Deshalb wurden verschiedene Ansätze zur Optimierung untersucht, wie Veränderungen der Netztopologie, Hyperparameter-tuning, Hinzufügen weiterer Features, Verwendung von synthetisch erzeugten Daten (durch Überlagerungen von Ground-Truth-Messungen). Allerdings brachten all diese Massnahmen keinen nennenswerten Verbesserungen (siehe Kapitel Ergebnisse).



- Ein Problem in der Kundenschnittstelle der L+G Smartmeter im Zusammenhang mit dem smart-me L+G Modul (welches für die Datenaufzeichnung benötigt wird) hat bei der Energie Thun zu einem Unterbruch des Smartmeter-Rollouts geführt. Die Akquisition von Pilothaushalten bei der Energie Thun wurde dadurch über mehrere Monate verzögert.

Projektanpassungen

Von einer Lastaufschlüsselung mittels NIALM wurde im weiteren Verlauf des Projekts gänzlich abgesehen, da gezeigt werden konnte, dass der geplante Ansatz keine kommerziell verwertbaren Ergebnisse liefert. Die Aufschlüsselung der einzelnen Verbraucher für das Feedback-System wurde stattdessen mit Messungen über smart-me Phasen-Meter und Plugs durchgeführt. Die Projektziele mussten somit nicht geändert werden.

2.6 Pilotbetrieb

Für die Akquisition und Rekrutierung der Pilotteilnehmer wurden folgende Arbeiten durchgeführt:

- Erstellen und Einholen Einverständniserklärung für die Pilotkunden
- Akquisition der Pilotkunden
- Vorbereitung der nötigen Messinfrastruktur für die Pilothaushalte
- Richten der Hardware für die Pilotinstallationen
- Schulung der Installateure anhand einer exemplarischen Installation und Inbetriebnahme der Messinfrastruktur in einem Pilothaushalt

2.7 User Front-End

Über das User-Front-End soll der Bewohner eines mit einem SmartNIALMeter-System ausgerüsteten Hauses, die Daten der Lastaufschlüsselung abrufen können. Diese Daten werden grafisch aufbereitet dargestellt und in einen verständlichen Kontext gebracht. Auch bietet es die Möglichkeit, vom Energieversorger personalisierte Energiespartipps zu erhalten. Für das User-Front-End wurden in der Anfangsphase des Projektes verschiedene Design-Vorschläge erarbeitet. Ein exemplarische Designbeispiel ist in folgender Abbildung zu sehen:

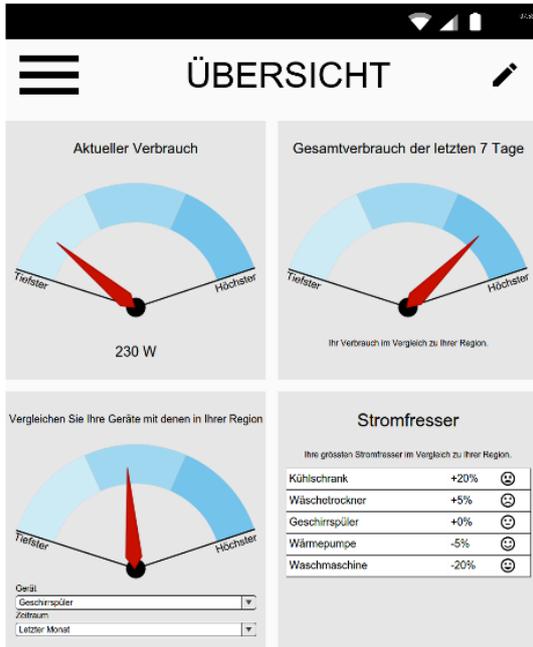


Abbildung 11: Design-Entwurf User Front-End

Das letztendlich realisierte User Front-End in Form einer WebApp ist dem Kapitel Ergebnisse zu entnehmen.



3 Ergebnisse

3.1 Datenaufzeichnungen aus Test- und Pilotbetrieb

Wir verfügen über eine Dateninfrastruktur, welche alle Anforderungen für eine permanente Aufzeichnung, Vorverarbeitung, Auswertung und Anzeige der Daten erfüllt.

Die folgenden beiden Abbildungen zeigen eine Übersicht aller durchgeführten Installationen inklusive der verbauten Messgeräte, der On-Off-Detektoren sowie der gemessenen Stromverbraucher:

building	owner	start_date	total	boiler	coffee_machine	dish_washer	electric_vehicle_charger	freezer	fridge	fridge-freezer	heatpump	main_meter	oven	stove	stove-oven	tumble_dryer	ventilation	washing_machine
1	EKZ	2018-02-27	6	1		1						1						1
2	EKZ	2018-06-29	8	1		1			1			1	1	1		1		1
3	EKZ	2018-04-24	7			1	1		1			1			1	1		1
4	EKZ	2019-11-27	5					1		1		1				1		1
5	EKZ	2019-11-29	3					1		1		1						
6	EKZ	2020-03-03	5					1		1		1				1		1
7	EKZ	2020-02-05	5					1		1		1				1		1
8	EKZ	2019-11-29	3			1				1		1						
9	EKZ	2020-02-18	4			1		1				1						1
10	EKZ	2020-02-18	4				1	1		1		1						
11	EKZ	2019-11-28	5					1		1		1				1		1
12	EKZ	2020-02-18	5			1		1				1				1		1
13	EKZ	2019-11-29	4					1		1		1				1		
14	EKZ	2020-02-05	4					1				1				1		1
15	EKZ	2019-11-29	5					1		1		1				1		1
16	EKZ	2020-01-26	3					1				1				1		
17	ET	2018-03-22	8		1	1			1			1		1		1	1	1
18	ET	2018-03-26	8	1		1			1			1		1		1	1	1
19	ET	2019-11-28	5					1		1		1				1		1
20	ET	2019-11-28	7			1		1		1	1	1				1		1
21	ET	2019-11-28	3					1				1				1		
22	IHL	2018-02-01	3	1	1			1										
23	IHL	2018-02-01	7	1		1		1				1	1	1				1
24	IHL	2018-06-12	8	1		1		1	2			1		1		1		
	EKZ		76	2	0	6	2	12	3	9	0	16	1	2	1	11	0	11
	ET		31	1	1	3	0	3	2	2	1	5	0	2	0	5	2	4
	IHL		18	3	1	2	0	3	2	0	0	2	1	2	0	1	0	1
	total		125	6	2	11	2	18	7	11	1	23	2	6	1	17	2	16

Abbildung 12: Übersicht Installationen - Messgeräte



building	owner	start date	total	boiler	electric_heating	dish_washer	heatpump	stove	tumble_dryer	washing_machine
1	EKZ		0							
2	EKZ		0							
3	EKZ		0							
4	EKZ		2				1	1		
5	EKZ		1					1		
6	EKZ		2	1					1	
7	EKZ		2	1				1		
8	EKZ		2						1	1
9	EKZ		3	1			1	1		
10	EKZ		3	1		1		1		
11	EKZ		0							
12	EKZ		3	1	1			1		
13	EKZ		2	1				1		
14	EKZ		2	1				1		
15	EKZ		3	1			1	1		
16	EKZ		3	1			1	1		
17	ET		0							
18	ET		0							
19	ET		2				1	1		
20	ET		1						1	
21	ET		2				1	1		
22	IHL		0							
23	IHL		0							
24	IHL		0							
	EKZ		28	9	1	1	4	11	1	1
	ET		5	0	0	0	2	3	0	0
	IHL		0	0	0	0	0	0	0	0
	total		33	9	1	1	6	14	1	1

Abbildung 13: Übersicht Installationen - On-Off Detektoren

Sämtliche gemessene Rohdaten sind in anonymisierter und komprimierter Form über den Clouddienst des iHomeLab der Hochschule Luzern den Projektteilnehmern zum Download bereitgestellt:

▼ SmartNIALMeter	17.02.2020, 16:03	--	Ordner
▶ house_01	17.02.2020, 11:12	--	Ordner
▶ house_03	14.02.2020, 17:26	--	Ordner
▶ house_04	14.02.2020, 12:50	--	Ordner
▼ house_05	17.02.2020, 09:59	--	Ordner
h electric_vehicle_charger.tar.gz	17.02.2020, 08:53	90.3 MB	gzip-komprimiertes Archiv
h stove-oven.tar.gz	17.02.2020, 08:46	84 MB	gzip-komprimiertes Archiv
h fridge.tar.gz	17.02.2020, 08:42	54.4 MB	gzip-komprimiertes Archiv
h main_meter.tar.gz	17.02.2020, 08:50	51.9 MB	gzip-komprimiertes Archiv
h dish_washer.tar.gz	17.02.2020, 08:54	29.2 MB	gzip-komprimiertes Archiv
h tumble_dryer.tar.gz	17.02.2020, 08:47	25.3 MB	gzip-komprimiertes Archiv
h washing_machine.tar.gz	17.02.2020, 08:48	16.3 MB	gzip-komprimiertes Archiv
▼ house_06	17.02.2020, 12:52	--	Ordner
h main_meter.tar.gz	17.02.2020, 12:51	9.2 MB	gzip-komprimiertes Archiv
h fridge-freezer.tar.gz	17.02.2020, 12:51	8.8 MB	gzip-komprimiertes Archiv
h freezer.tar.gz	17.02.2020, 12:50	7.7 MB	gzip-komprimiertes Archiv
h washing_machine.tar.gz	17.02.2020, 12:51	6.1 MB	gzip-komprimiertes Archiv
h tumble_dryer.tar.gz	17.02.2020, 12:51	3.2 MB	gzip-komprimiertes Archiv
▶ house_07	17.02.2020, 12:52	--	Ordner
▶ house_11	17.02.2020, 12:52	--	Ordner
▶ house_12	17.02.2020, 15:09	--	Ordner
▶ house_17	17.02.2020, 15:10	--	Ordner
▶ house_19	17.02.2020, 15:10	--	Ordner
▶ house_20	17.02.2020, 15:49	--	Ordner
▶ house_21	17.02.2020, 15:50	--	Ordner
▶ house_22	17.02.2020, 15:50	--	Ordner
▶ house_26	17.02.2020, 10:04	--	Ordner
▶ house_27	17.02.2020, 10:32	--	Ordner
▶ house_28	17.02.2020, 16:02	--	Ordner
▶ house_29	17.02.2020, 16:03	--	Ordner
▶ house_30	19.02.2020, 17:07	--	Ordner
▶ house_48	14.02.2020, 16:47	--	Ordner
▶ house_49	17.02.2020, 09:59	--	Ordner

Abbildung 14: Bereitstellung Rohdaten



3.2 User Front-End

Die folgenden 4 Abbildungen zeigen die realisierten Ansichten Gesamtverbrauch, Details, Monatsvergleich und Gerätevergleich des entwickelten User Front-Ends, das den Pilotteilnehmern über personalisierte Benutzerzugänge in Form einer WebApp zur Verfügung gestellt wurde:



Abbildung 15: GUI - Gesamtverbrauch



Abbildung 16: GUI - Details

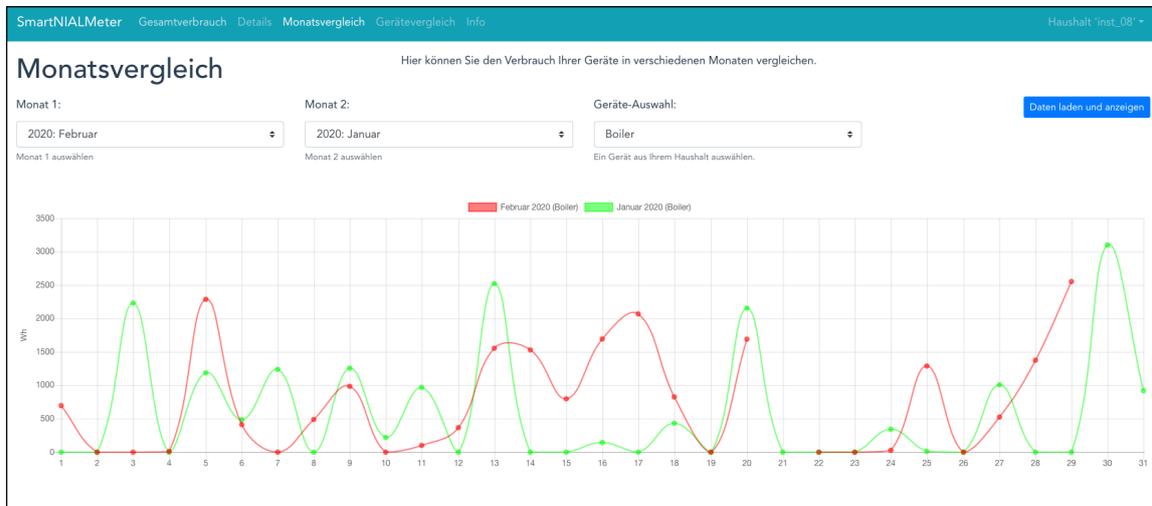


Abbildung 17: GUI - Monatsvergleich

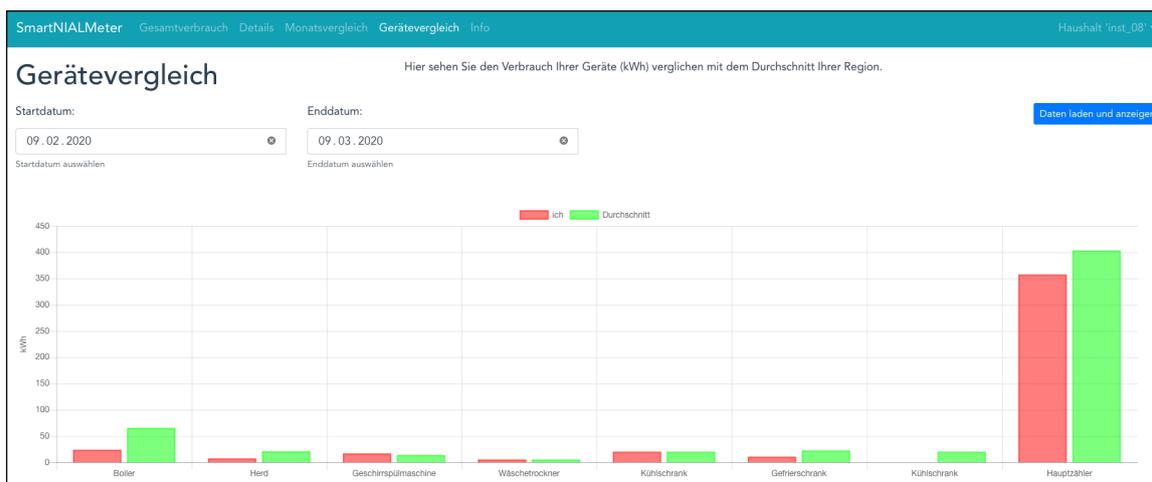


Abbildung 18: GUI - Gerätevergleich



3.3 Erkennungsalgorithmen

Die Ergebnisse entsprechen nicht den zu Beginn des Projekts gestellten, hohen Erwartungen. Sowohl für Geräte, die mit Beispielen (Aktivierungen) im Trainingsdatensatz vertreten sind, als auch für Geräte von «unseen houses», also Datensätze von Haushalten, welche nicht im Trainingsdatensatz vorhanden sind, ist eine Optimierung hin zu einer besseren Generalisierung notwendig. Nachfolgend sind die Daten grafisch dargestellt, die es ermöglichen, die Effizienz des zur Erkennung verwendeten Algorithmus zu quantifizieren. Die Diagramme zeigen im unteren Teil den gemessenen Gesamtverbrauch (Mains) des exemplarischen Haushalts sowie den gemessenen (Ground Truth) und disaggregierten (Predicted) Verbrauch eines Geräts auf. Der obere Teil zeigt den aus Disaggregation und Ground Truth resultierenden Fehler. Bewertet werden die Ergebnisse mit dem Normalized Total Error (NTE) und der Normalized Absolute Distance (NAD). Der NTE berechnet sich über die Formel (1), die NAD über die Formel (2). Der NTE ist dabei für die Energieberechnung aussagekräftiger, da er die Genauigkeit der Energieberechnung am Ende einer Messperiode angibt. Ist z.B. $NTE = 0.08$ dann weicht die Abschätzung der Energie über die Messperiode um 8% vom realen Wert ab. Daraus lässt sich die Messabweichung in Wh ableiten. Die NAD gibt an, wie gross die durchschnittliche Abweichung der einzelnen, geschätzten Momentanwerte von den wahren Momentanwerten ist. Sie ist das Mass für die Treffsicherheit der Algorithmen. Der NTE ist im Normalfall um einiges besser als die NAD, da sich beim NTE positive und negative Fehler der geschätzten Momentanwerte gegenseitig kompensieren können.

$$NTE = \frac{|\sum_t y_t - \sum_t \hat{y}_t|}{\sum_t y_t} \quad (1)$$

$$NAD = \frac{\sum_t |y_t - \hat{y}_t|}{\sum_t y_t} \quad (2)$$

Dabei sind y_t die einzelnen realen Momentanwerte und \hat{y}_t die geschätzten Momentanwerte.

Während die Ergebnisse für den Boiler (Abbildung 19 und Abbildung 20), bei dem die Aktivierungen einer rechteckigen On-Off Charakteristik gleicht, noch einigermaßen brauchbar sind (NTE liegt zwischen 0,08 und 0,13), zeigen die Ergebnisse für die Waschmaschine mit variablen Verlaufskurven (Heizen, (Vor-)Waschen, Spülen, Schleudern etc.) hohe Fehlerwerte mit NTE über 1 (Abbildung 21 und Abbildung 22), weshalb die Algorithmen für einen kommerziellen Einsatz nicht geeignet sind.

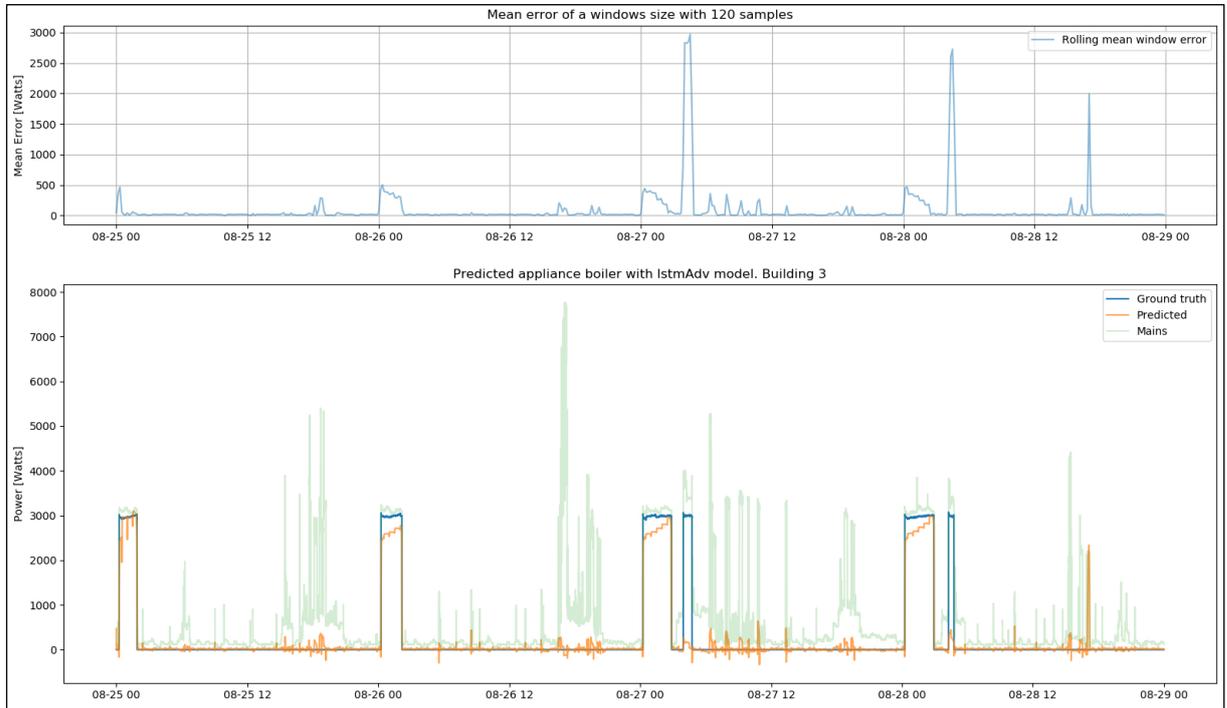


Abbildung 19: Genauigkeit der Erkennung bei der Validierung am Beispiel eines Boilers (NTE = 0.13, NAD = 0.29)

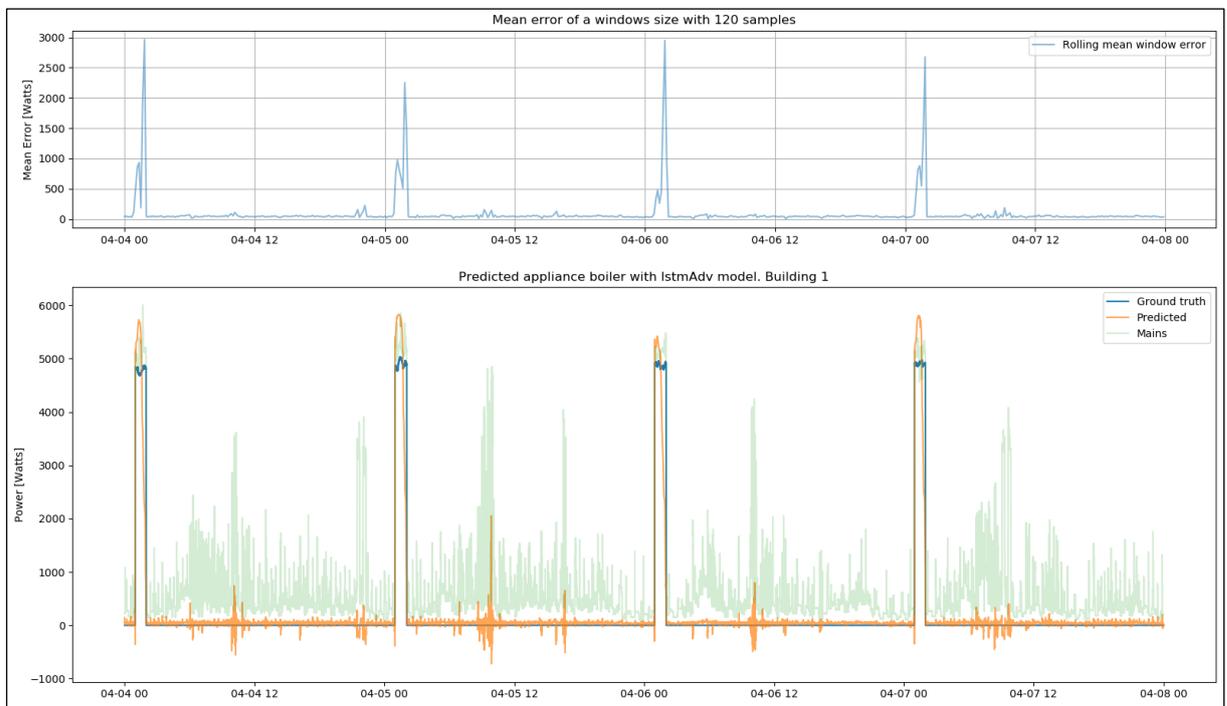


Abbildung 20: Genauigkeit bei einem «unseen house» am Beispiel eines Boilers (NTE = 0.08, NAD = 0.46)

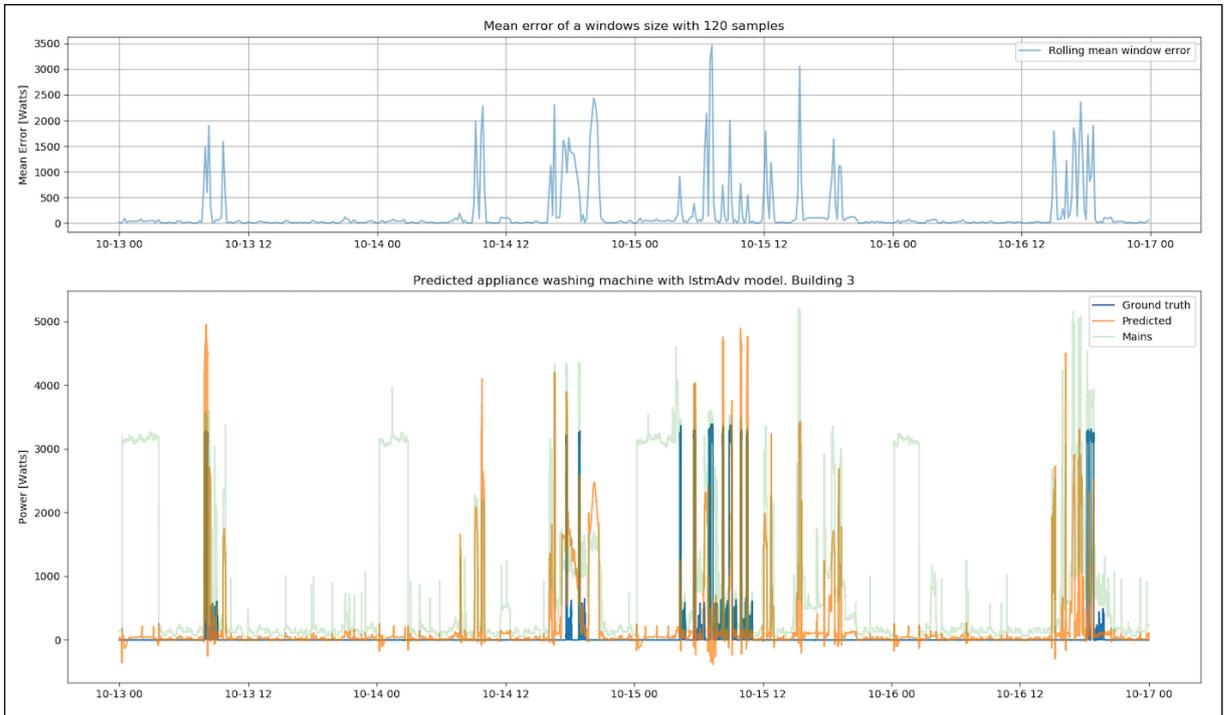


Abbildung 21: Genauigkeit der Erkennung bei der Validierung am Beispiel einer Waschmaschine (NTE = 4.76, NAD = 6.00)

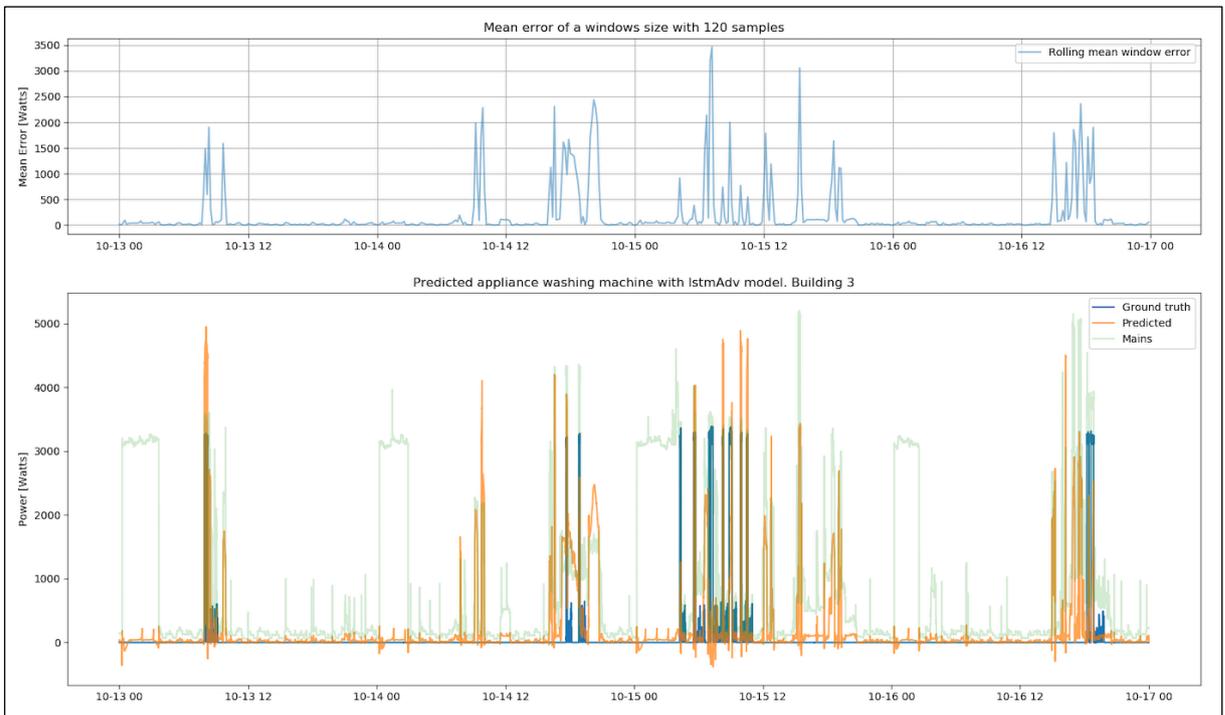


Abbildung 22: Genauigkeit bei einem «unseen house» am Beispiel einer Waschmaschine (NTE = 1.69, NAD = 2.60)



3.4 Kundenumfrage

Da eine Umfrage unter den 12 Teilnehmern des Pilotprojekts aufgrund der Anzahl der Teilnehmer nicht als repräsentativ angesehen werden konnte, wurde beschlossen, eine weitere Befragung über ein Online-Panel bestehend aus Schweizer Haushalten vom Datenanbieter „GapFisch“ durchzuführen.

Ziel der Befragungen war die Abschätzung der Kundenakzeptanz ausgewählter, auf Smart-Meter-Daten basierender Angebote. Dazu wurden Teilnehmerinnen und Teilnehmer aus der Schweiz zu ihrer Wohnungssituation, ihrem Energieverbrauch und ihrer Umwelteinstellung befragt und gebeten, unterschiedliche Ansätze zur Verbrauchsvisualisierung, mögliche Dienstleistungsangebote sowie Modelle zur Datenverarbeitung zu bewerten.

1) Informationen zur Stichprobe

Für die Befragung wurde ein Online-Panel bestehend aus Schweizer Haushalten vom Datenanbieter „GapFisch“ erworben. Die Umfrage fand im Zeitraum zwischen dem 20. und dem 27. April 2020 statt und erfolgte anonym mit Hilfe eines Online-Formulars. Zu keinem Zeitpunkt wurden durch das Forschungsteam Daten erhoben oder gespeichert, welche Rückschlüsse auf die Identität der Befragten zulassen.

Die Teilnehmerinnen und Teilnehmer waren volljährig; zusätzliche Einschränkungen für eine Teilnahme wurden nicht festgelegt. Insgesamt wurden 304 Fragebögen vollständig beantwortet.

Das Durchschnittsalter der Befragten betrug 45 Jahre, 76% waren nach eigenen Angaben berufstätig und 40% gaben an, in einem Eigenheim zu wohnen. Die Einkommensverteilung der Teilnehmer findet sich in Abbildung 23. Die Umwelteinstellung der Studienteilnehmer ist in Abbildung 24 zusammengefasst. Es lässt sich eine generelle positive Umwelteinstellung unter den Teilnehmern erkennen, welche für eine Befragung in der Schweiz nicht ungewöhnlich ist. Der durchschnittlich angegebene Stromverbrauch pro Haushalt beträgt 4'547 kWh pro Jahr (zum Vergleich: Der tatsächlicher Durchschnittsverbrauch Schweizer Haushalte belief sich in 2019 auf 5'200 kWh [8]). Die Abweichungen von den tatsächlichen Mittelwerten Schweizer Haushalte erachtet das Forscherteam für den Zweck einer ersten Bewertung von potentiellen Energiedienstleistungen als hinreichend gering, was die Konfidenz beim Schluss von der Stichprobe auf die gesamte Population erhöht.



Abbildung 23: Monatliches Nettohaushaltseinkommen

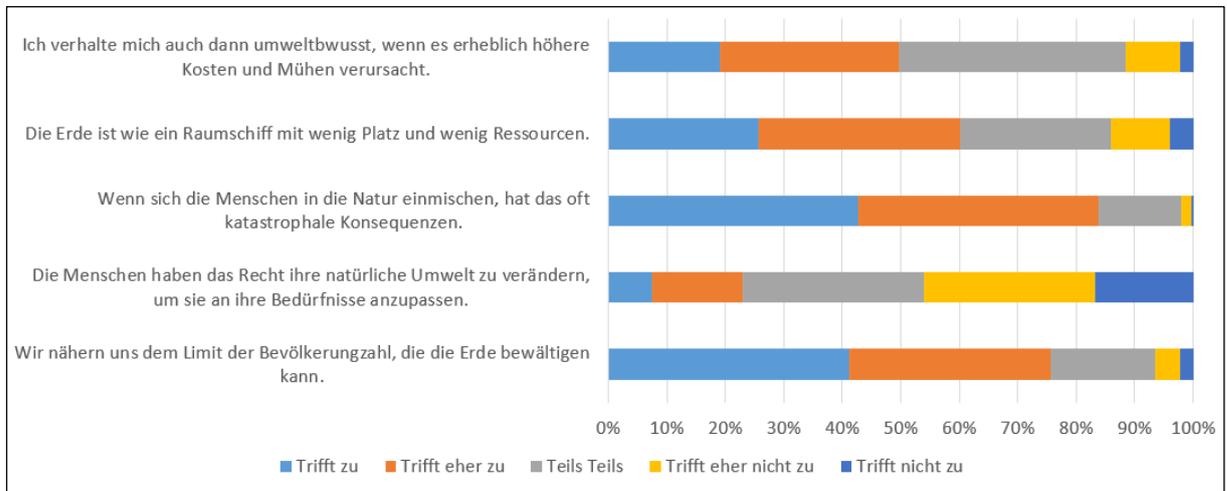


Abbildung 24: Umwelteinstellung der Befragten

2) Nutzung von Energieberatungsleistungen / Verbrauchsoptimierungen

Von den Befragten gaben 10% an, innerhalb der vergangenen fünf Jahre eine konventionelle Energieberatung in Anspruch genommen zu haben lassen (siehe Abbildung 25). Die Beratung wurde in 7% der Fälle von einem EVU, in 57% von der Gemeinde, in 10% von einem EVU und der Gemeinde und in 26% der Fälle von einem anderweitigen Anbieter (privat, Energieberatung Kanton, Elektrogeschäft, Ingenieurbüro) durchgeführt.

Die Hälfte der Befragten, die eine Energieberatung nutzten, haben sich zum Thema Wärmepumpe beraten lassen, in 37% der Fälle zum Thema Gebäudeisolation, in 33% der Fälle zum Thema thermische Solaranlage und in 27% der Fälle zum Thema Photovoltaik. Eine allgemeine Beratung fand bei 30% der Teilnehmer statt. In 13% der Fälle haben sich die Teilnehmer in den Bereichen Wärmepumpe und Photovoltaik, in 10% in Bereichen Wärmepumpe und thermische Solaranlage und in 7% in allen drei Bereichen beraten.

Insgesamt nutzt nur ein kleiner Teil der Haushalte das Angebot der mitunter kostenlos offerierten Beratungsleistungen. Auslöser sind meist größere geplante Investitionen im Bereich Sanierung, PV- und Solarthermie sowie die Überprüfung großer Verbraucher (z.B. Wärmepumpen). Ein Haushalt, der in einem Bereich beraten wurde, fragt mit hoher Wahrscheinlichkeit auch eine Beratung zu einem anderen Thema nach.

Hinsichtlich der durchgeführten Optimierungen in den letzten fünf Jahren lässt sich beobachten, dass die Bereiche Elektrogeräte und Beleuchtung am Stärksten vertreten sind. Eine Optimierung im Bereich der Elektrogeräte haben bereits 51% der Befragten durchgeführt. Eine geplante Optimierung streben 32% der Teilnehmer an. 38% der Befragten, die bereits eine Optimierung vorgenommen haben, planen eine weitere.

Im Bereich Beleuchtung haben 59% der Teilnehmer in den letzten fünf Jahren eine Optimierung vorgenommen, 28% planen eine solche. Eine erneute Optimierung planen 27% derer, die bereits eine erste vorgenommen haben.

Steigende Bedeutung hinsichtlich einer Optimierung lässt sich in den Bereichen Heizsystem und Elektromobilität beobachten. So haben bisher 15% der Befragten eine Optimierung im Bereich der Heizsysteme vorgenommen, 19% planen eine solche.

Im Bereich Elektromobilität gaben 7,6% der Befragten an, eine Optimierung vorgenommen zu haben. Diese deckt sich sehr gut mit dem Marktanteil von Personenwagen von rund 8%, die am Stromnetz aufgeladen werden können [9]. Rund 20% der Befragten planen, in mindestens teilweise elektrisch betriebene PKW zu investieren.



Der Hauptgrund für einen Investitionsverzicht sind die hohen Kosten (53% der Befragten). Als weitere wichtigen Gründe für einen Verzicht wurden zum einen der Zeitmangel (15%) und zum anderen ein unklarer Nutzen (17%) genannt.

Grundsätzlich lässt sich festhalten, dass ein großer Teil der Haushalte kleinere Massnahmen und ein nennenswerter Teil der Haushalte Massnahmen mit grossem Potential zur CO₂-Reduktion erwägt. Zeitmangel und unklarer Nutzen sind angegebene Gründe, die sich durch Dienstleistungen unmittelbar adressieren lassen.

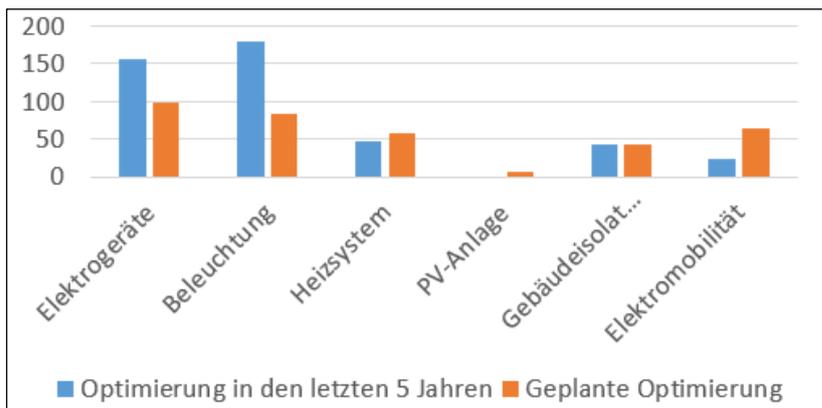


Abbildung 25: Kategorien der erfolgten oder geplanten Optimierungsmassnahmen

3) Verbrauchs-Feedback und -Visualisierung

Ansätze wie Verbrauchs-Feedback können dazu beitragen, Hürden von Optimierungsmassnahmen abzubauen. Hinsichtlich des Stromverbrauchs sollten die Befragten vier verschiedene Visualisierungsmöglichkeiten in eine von ihnen präferierte Reihenfolge bringen. Die am häufigsten als wichtigste («Rang 1») bewertete Visualisierung ist mit 45% die Darstellung des Gesamtverbrauchs im Vergleich zum Durchschnitt.

Die Übrigen Visualisierungsansätze folgen mit deutlichem Abstand: Eine Übersicht von allen Geräten im Vergleich zum Durchschnitt ist mit 24% die als zweithäufigste mit «Rang 1» ausgewählte Visualisierungsmöglichkeit. Im Gegensatz zum gesamten Stromverbrauch lässt sich hier der Verbrauch einzelner Geräte, z. B. vom Kühlschrank, mit dem Durchschnittsverbrauch aller Geräte der jeweiligen Art in der Region vergleichen.

Ähnlich häufig wurde der Zeitverlauf gewählt; diese Anzeige wählten 20% als wichtigste Variante. Die am wenigsten stark präferierte Visualisierung (11% «Rang 1») ist der Vergleich von Geräten oder dem Gesamtverbrauch über einen wählbaren Zeitraum (siehe Abbildung 26).

Peer-Vergleiche würden als bevorzugte Version ausgewählt. Solche Vergleiche zeigen regelmäßig auch in der Praxis grössere Wirkung auf den Verbrauch als z.B. x-t-Diagramme. Die Visualisierung der Lastaufschlüsselung folgt auf dem zweiten Platz und kann somit die Darstellungsmöglichkeiten für einen grossen Teil potentieller Nutzer attraktiver gestalten.

Mehrere große Feldstudien konnten zeigen, dass Peer-Vergleiche (bzw. deskriptives normatives Feedback) großen Einfluss auf das Verbrauchsverhalten haben [10]. Allerdings muss bei dieser Art des Feedbacks bedacht werden, dass häufig ein «Trend zur Mitte» erfolgt: Feedback-Empfänger, deren Verbrauch oberhalb des Medians liegen, passen ihr Verhalten nach unten an und erzielen so teils große Einspareffekte; solche, die besser abschneiden als die Referenzgruppe, steigern tendenzielle ihren Verbrauch. Dieser ungewollte Trend zur Mitte kann durch die Wahl einer «ambitionierten» Referenzgruppe oder mit Hilfe von zusätzlichem injunktivem normatives Feedback aufgehoben werden.

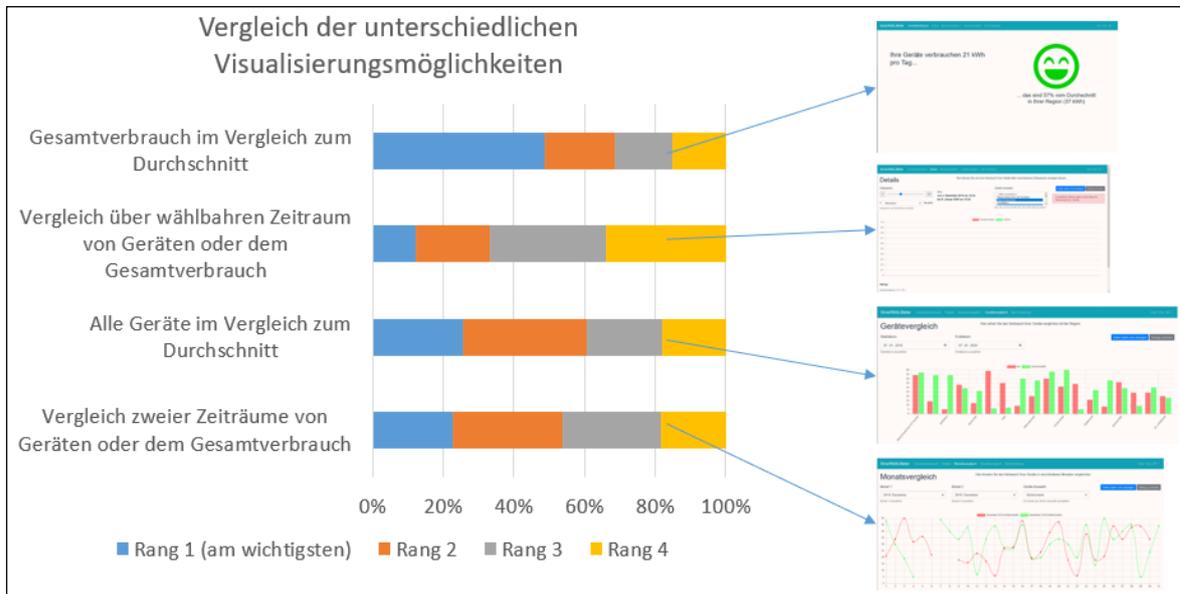


Abbildung 26: Bewertung der Feedback-Optionen

4) Bewertung zusätzlicher Dienstleistungen

Den Befragten wurden sechs potentielle Dienstleistungen vorgestellt. Das Interesse sowie die Zahlungsbereitschaft für die folgenden Dienstleistung sollte bewertet werden:

- Benachrichtigung
- monatlichen Schätzung ihres möglichen Einsparpotentials
- personalisierten Handlungsempfehlungen
- Monitoring oder Optimierung der Heizungsanlage
- Optimierung des Eigenverbrauchs
- Monitoring oder Optimierung der Photovoltaik-Anlage

Mit 74% haben die Befragten das grösste Interesse an einer Benachrichtigung bei ungewöhnlich hohem Stromverbrauch. Im Durchschnitt wären sie bereit, 10 CHF pro Jahr für solch eine Dienstleistung zu zahlen. Ungefähr 60% der Befragten haben ein Interesse an einer monatlichen Schätzung ihres Einsparpotentials. Sie wären im Mittel bereit, 17 CHF pro Jahr für diese Dienstleistung zu zahlen. Ein ähnlich grosses Interesse besteht mit 57% an personalisierten Handlungsempfehlungen auf Basis der individuellen Verbrauchsdaten. Die Befragten wären bereit 18 CHF im Durchschnitt für diese Dienstleistung zu zahlen. Im Hinblick auf die Möglichkeit zum Monitoring oder zur Optimierung der Heizungsanlage bekunden ungefähr 40% der Befragten ihr Interesse an solch einer Dienstleistung (Anmerkung: das entspricht dem Anteil der Befragten, die in einem Eigenheim wohnen). Im Durchschnitt wären sie bereit, 20 CHF dafür aufzuwenden. Von den Interessenten dieser Dienstleistung besitzen 21% eine Wärmepumpe. Diese Gruppe wäre bereit, 14 CHF im Durchschnitt für diese Dienstleistung zu zahlen (Anmerkung: Viele Wärmepumpen-Nutzer haben bereits ein deutlich teureres Wartungs-Abonnement). Für die Möglichkeit zur Optimierung des Eigenverbrauchs bei Nutzung einer PV-Anlage interessieren sich ungefähr 30% der Befragten. Im Durchschnitt wären sie bereit, 22 CHF für diese Dienstleistung zu zahlen. Am wenigsten Interesse bekunden die Befragten an der Möglichkeit zum Monitoring oder zur Optimierung einer Photovoltaik-Anlage. Hier wären mit 25% dazu bereit, 22 CHF für eine Dienstleistung zu zahlen (siehe Abbildung 27). Die Zahlungsbereitschaft wurde ohne Nennung finanzieller Einsparpotentiale erfragt, da keine Ankerpunkte gesetzt werden sollten und da relative kleine Sparpotenziale vermutlich nicht den primären Anreiz für niederschwellige Handlungen darstellen [11].



Die Umfrageteilnehmerinnen und -teilnehmer äußern ein erhebliches Interesse sowie eine gute Zahlungsbereitschaft für datenbasierte Energiedienstleistungen.

Die relative hohe genannte Zahlungsbereitschaft steht im Widerspruch zur geringen Inanspruchnahme von (teils kostenlosten) konventionellen Energieberatungsleistungen. Für eine Inanspruchnahme scheinen allerdings nicht der Kosten, sondern die organisatorische/zeitliche Hürde wesentlich zu sein (z.B. die erforderliche Eigeninitiative, Terminfindung, Erfordernis eines halben Urlaubstags etc.). Hier können niederschwellige datenbasierte Dienstleistungen möglicherweise dazu beitragen, diese Hürde zu überwinden.

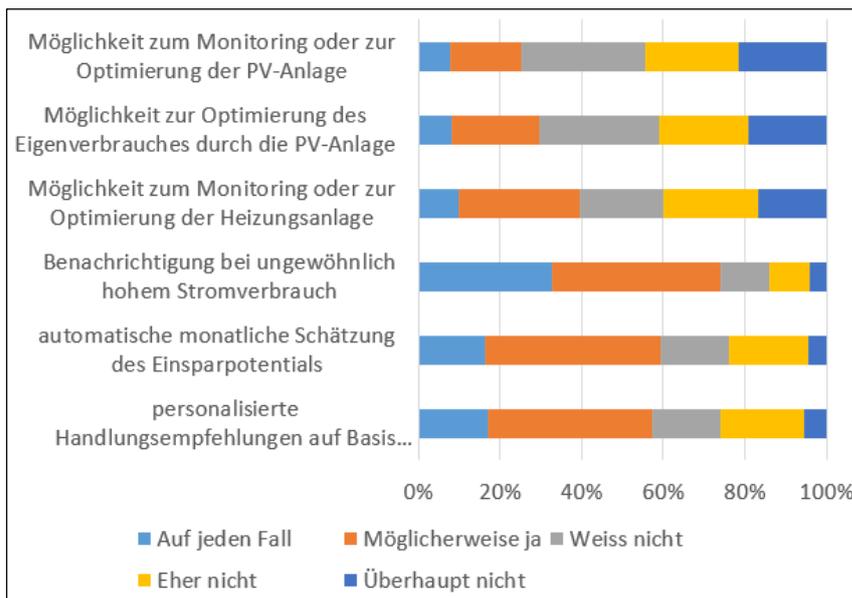


Abbildung 27: Interesse an zusätzlichen Dienstleistungen

5) Bereitschaft zur Datenfreigabe

Untersucht wurde ferner die Bereitschaft, Daten zum Zweck eines Dienstleistungsangebotes zugänglich zu machen. 74% der Befragten sind grundsätzlich bereit, ihre Daten ihrem EVU zur Verfügung zu stellen. Hinsichtlich öffentlicher Einrichtungen oder unabhängigen Dienstleistern aus der Schweiz ist mit 38% und 34% die Motivation zur Bereitstellung der Daten deutlich geringer, wobei hierbei aber ein erheblicher Teil der Befragten noch unentschlossen ist (ca. ein Drittel). Am wenigsten Vertrauen haben die Teilnehmer in Unternehmen wie Google oder Apple; hier besteht lediglich bei 13% die Bereitschaft, die Verbrauchsdaten zugänglich zu machen (Abbildung 28). Hierbei muss angemerkt werden, dass ein attraktives Angebot und ein «bequemes Opt-in» gegen einen kleinen Vorteil die Bereitschaft für ein Einverständnis zur Datennutzung regelmässig drastisch erhöht.

Das größte Vertrauen bezüglich des ordnungsgemäßen Umgangs mit den persönlichen Verbrauchsdaten wird dem jeweiligen Energieversorger zugeschrieben. Grosse Anbieter wie Google schneiden erheblich schlechter ab.

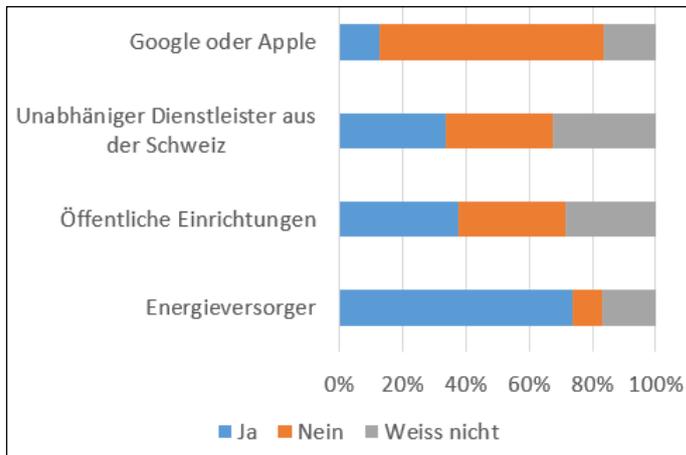


Abbildung 28: Bereitschaft zur Bereitstellung von Verbrauchsdaten an potentielle Energiedienstleistungsanbieter



4 Erkenntnisse und Schlussfolgerungen

4.1 Herausforderungen bei den Datenaufzeichnungen

Der Aufbau und Betrieb der Installationen und der Infrastruktur für die Datenaufzeichnungen ist mit zahlreichen Herausforderungen behaftet und erfordert enormen Zeitaufwand. Im Folgenden sind die wesentlichen Erkenntnisse aufgelistet:

- Die smart-me Zähler mussten alle so installiert werden, dass sie jeweils nur einen einzigen Verbraucher messen. Die Smartmeter mussten wir jeweils zwischen dem bestehenden Stromzähler und dem Elektrotabelleau installieren. Dies alles hat sich als schwierig zu planen und allgemein recht aufwändig herausgestellt, da in jedem Haushalt die Elektroinstallation anders ist. Da zur Installation jeweils nur ein Besuch bei den Testteilnehmern geplant war mussten wir anhand von Fotos, welche die Testteilnehmer aufgenommen hatten, beurteilen, wie genau die Geräte installiert werden sollen. Auch mussten wir genügend flexibel sein, um auf Unvorhergesehenes reagieren zu können.
- Die WLAN-Verbindungen von den Messzählern zu den WLAN-Routern im Haus sind nicht immer zuverlässig. Für die WLAN-Verbindung zu den Metern haben wir immer einen eigenen dedizierten WLAN-Router – und bei Bedarf Repeater – verwendet und nie ein bestehendes WLAN im Haus benutzt. Es kommt ab und zu vor, dass WLAN-Router «blockieren» und neu gestartet werden müssen (Reset mit Power OFF – ON).
- In der Regel haben wir für die Verbindung der WLAN-Router zum Internet bestehende, drahtgebundene Internetverbindungen im Haus benutzt. Bei zwei Installationen hat das zu Problemen geführt. In einem Fall haben wir schlussendlich die Messinfrastruktur entfernt und im anderen Fall die Internetverbindung mit einem 3G Mobile-Netzwerk Router realisiert.
- Es hat sich gezeigt, dass einzelne Router, Zähler oder smart-me Geräte zwischendurch ausfallen. Dies führt zu Datenausfällen, mit welchen in der Datenaufbereitung umgegangen werden muss.
- Es müssen einzeln Messgeräte ausgetauscht werden, was wiederum in der Datenaufbereitung berücksichtigt werden muss (neue Geräte IDs müssen mit alten «gematcht» werden etc.).
- Messdaten werden vom Meter zur smart-me Cloud übertragen und vom virtuellen Rechner in der Google VM Infrastruktur von der smart-me Cloud ausgelesen. Beide Datenverbindungen laufen über das Internet. Dadurch ergeben sich unterschiedliche und nicht vorhersehbare Laufzeiten für die Messdaten. Aufgrund von Laufzeitunterschieden und Verbindungsunterbrüchen kann deshalb nicht garantiert werden, dass genau alle 5 Sekunden Messwerte gespeichert werden können. Abweichungen von +/- 2 Sekunden für «Zeitstempel» der Messwerte sind regelmässig zu beobachten.
- Damit bei einem Absturz von Applikationen zur Messdatenerfassung nicht über mehrere Tage (z.B. an Wochenenden) unentdeckt Messdaten fehlen, haben wir uns entschieden den virtuellen Rechner täglich neu zu booten. Dies hat zur Folge, dass während dem Reboot (ca. 1 Minute) keine Messdaten aufgezeichnet werden.

Aufgrund der oben aufgeführten Punkte kommt es immer wieder zu Datenausfällen. Abbildung 29 zeigt exemplarisch für den Zeitraum vom 20.11.2019 – 10.02.2020 den prozentuellen Anteil an Datenausfällen (horizontale Achse : Zeit, vertikale Achse : Messgeräte). Dunkle Färbung deutet auf gar keine bis wenig Datenausfälle hin, helle Färbung auf viele Datenausfälle, wobei der hellste Farbwert einem Komplettausfall (100%) entspricht.

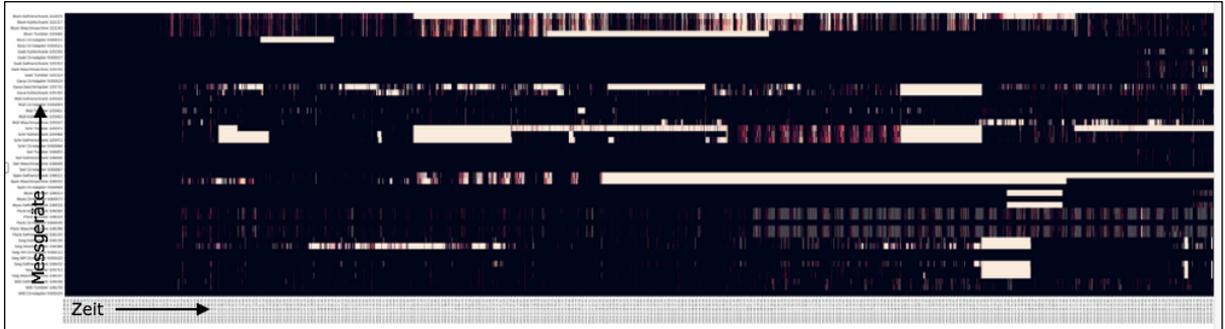


Abbildung 29: Heatmap Datenausfälle

4.2 Erkennungsalgorithmen

Die mit den Algorithmen von Kelly & Knottenbelt erzielten und publizierten Ergebnisse basieren auf dem Datensatz UK-DALE. Diese Ergebnisse konnten jedoch mit unserem selbst gemessenen Datensatz (SmartNIALMeter) nicht reproduziert bzw. erreicht werden, weshalb dieser Ansatz für einen kommerziellen Einsatz nicht oder nur bedingt brauchbar ist. Nach Analyse der Daten und Ergebnisse konnten dafür zwei hauptsächliche Ursachen identifiziert werden:

1.) Hohe Varianz an unterschiedlichen Mustern (Leistungskurven) für einzelnen Verbraucher im Datensatz SmartNIALMeter

Die Varianz in den Mustern für einzelne Verbraucher wie beispielsweise der Waschmaschinen, ist bei unserem Datensatz um ein Vielfaches höher als beim UK-DALE-Datensatz, bei dem der Grossteil der Trainingsdaten aus einem einzigen Haus stammt (House Nr. 1 \approx 80% aller Daten) und zudem insgesamt überhaupt nur drei verschiedene Waschmaschinen vorhanden sind, die zudem auch sehr ähnliche Muster aufweisen. Die hohe Varianz in unserem Datensatz resultiert aus den 7 verschiedenen Waschmaschinen, die höchstwahrscheinlich von unterschiedlichen Herstellern stammen bzw. unterschiedlichen Fabrikaten zuzuordnen sind und deshalb in ihren Mustern eine höhere Varianz aufweisen. Anders als beim weniger variantenreichen Datensatz UK-DALE, ist der verwendete Algorithmus von Kelly & Knottenbelt aufgrund der hohen Varianz an unterschiedlichen Mustern bei unserem Datensatz nicht in der Lage, ausreichend genug zu generalisieren.

2.) Hohe Varianz in den Aktivierungszeiträumen im Datensatz SmartNIALMeter

Ein weiterer Unterschied zwischen den beiden Datensätzen liegt in den unterschiedlichen Aktivierungszeiträumen. Um beim Beispiel Waschmaschine zu bleiben, bewegen sich die Aktivierungszeiträume im UK-DALE-Datensatz vorwiegend zwischen 60 und 90 Minuten, während es im SmartNIALMeter-Datensatz ein viel breiteres Spektrum an Aktivierungszeiträumen gibt. Wie auch bei den Mustern liegt die Ursache in der höheren Anzahl und Varianz der verschiedenen Waschmaschinenhersteller- bzw. Fabrikate sowie deren vielfältigen Programmeinstellungsmöglichkeiten (Kurzprogramme, Vorwaschen, zahlreiche unterschiedliche Hauptwaschprogramme, Eco- und Speed-Optionen, Schleuderprogramme, etc.), wodurch sich in unserem Datensatz weiter verteilte Aktivierungszeiträume ergeben, die zwischen 30 und über 180 Minuten liegen. Ein ähnliches Bild bezüglich Aktivierungszeiträume zeigt sich auch bei den Kühl- und Gefrierschränken



5 Ausblick und zukünftige Umsetzung

5.1 Beurteilung der Hürden eines praxistauglichen Einsatzes von «non-intrusive Load-Monitoring-Ansätzen» in Haushalten

Unter *Non-intrusive Load Monitoring* versteht man die Aufschlüsselung des Verbrauchs eines Stromkunden (z.B. eines Haushalts oder Betriebs) in einzelne elektrische Lasten (Beleuchtung, Herd, TV, etc.) mit Hilfe eines zentralen Sensors. Damit grenzt sich das Verfahren von dezentralen Ansätzen ab, die einzelne Verbraucher mit separaten, diesen zugeordneten Sensoren erfassen. Beide Verfahren sollen eine Vielzahl von Anwendungsfällen ermöglichen. Dazu zählen Maßnahmen zur Steigerung der Energieeffizienz (etwa durch die Schaffung eines besseren Verständnisses des Verbrauchs einzelner Geräte oder durch die Identifikation von veralteten oder falsch eingestellten Geräten), die Entwicklung neuer Bezahl- und Geschäftsmodelle («pay per use», «energy contracting») bis hin zur Überwachung von Geräten zur Vorhersage von Defekten («predictive maintenance») oder zur Optimierung von Betriebszuständen.

Der Vorteil von zentralen Ansätzen liegt in der einfachen und damit kostengünstigen Installation der Messtechnik. Diesem Vorteil stehen zahlreiche Herausforderungen gegenüber, welche die Aufschlüsselung («Disaggregation») eines summarisch erfassten Leistungswertes mit sich bringen und auf die nachfolgend eingegangen wird.

Den bestehenden Herausforderungen und den zahlreichen Anwendungsfällen entsprechend hat sich die Forschung intensiv mit dem Themengebiet auseinandergesetzt. Google Scholar vermeldet für den Suchbegriff «non-intrusive load monitoring» [12] über 7'000 Treffer. Kommerzielle Anwendungen existieren bereits in der Industrie zur Überwachung von Anlagen. In Haushalten haben einige Unternehmen ambitionierte Lösungen angekündigt (z.B. eine genaue Ausweisung der Kosten je Gerät), eine nennenswerte Verbreitung hat in Haushalten jedoch noch nicht stattgefunden.

In diesem Kapitel soll auf Basis der gesammelten Erfahrung eine Einschätzung gegeben werden, welche Hürden einer weiteren Verbreitung von NILM in Haushalten entgegenstehen. Die Einschätzung umfasst Ansätze, die auf Daten von konventionellen Smart Metern (und damit auf 15-minütige Verbrauchswerte) aufbauen, da solche Stromzähler in einer großen Zahl von Haushalten installiert wurden bzw. werden und diskutiert darüber hinaus auch Lösungsversuche, die höherfrequente Abstraten heranziehen. Mit dieser Einschätzung soll die Erwartung an Forschung und Entwicklung zu NILM einem Realitäts-Check unterzogen werden, durch welchen die Ziele und Erfolgchancen von Projekten, die auf einen baldigen Praxiseinsatz von NILM hinarbeiten, hinterfragt werden können.

Bestehende Probleme bei einer praktischen Umsetzung

Das wesentliche praktische Problem der NILM-Ansätze offenbart sich beim Übergang vom Labor bzw. einer kleinen Anzahl an Testhaushalten in die Praxis: Die Erkennungsraten sind im Labor oder in der Entwicklungsumgebung meist zufriedenstellend, verschlechtern sich aber erheblich bei einer Anwendung auf leicht geänderte Datensätze oder Topologien, wie sie zwangsläufig bei einer Anwendung in neuen Haushalten vorzufinden sind. Für die geplanten Anwendungsfälle (z.B. eine präzise Aufschlüsselung nach Verbrauchern auf Rechnungen, Pay-per-use Anwendungen, Energy-Contracting-Modelle) sind die Resultate kaum ausreichend. Ein Training der Algorithmen in den Haushalten kann den «Praxis-Gap» zwischen Entwicklungsumgebung und Anwendung im Feld reduzieren, gestaltet sich aber schwierig (da zu zeitintensiv, zu viele Störfaktoren, zu wenige Trainingsfälle) und muss ggf. bei der Hinzufügung neuer Geräte wiederholt werden. Dies entspricht kaum den Erwartungen einer Mehrheit der Kunden an eine praxistaugliche Lösung.



Hinzu kommt, dass NILM-Ansätze oft auch dann für einen Praxiseinsatz nicht hinreichend geeignet sind, wenn sie für 90% der Kunden sehr gute Ergebnisse liefern würden, da die verbleibenden 10% der Installationen nicht mit dem Wertversprechen (und der Ausdauer der Service-Mitarbeiter) zu vereinbaren sind. Dies gilt insbesondere für Energieversorger, deren Kunden eine Erbringung von höchst zuverlässig und stets verfügbaren Leistungen erwarten.

Bestehende Hürden

Die bestehenden Hürden lassen sich auf folgende Gegebenheiten zurückführen:

Variabilität einzelner Geräte: Zahlreiche Geräte weisen Leistungsaufnahmen auf, welche von den (häufig veränderten) Einstellungen durch die Nutzer abhängen. Geräte, für die dies zutrifft, sind z.B. Kochplatten, dimmbare Beleuchtung, Lüftungsanlagen, Staubsauger etc. Viele dieser Geräte ändern ihre Leistungsaufnahme zusätzlich in Abhängigkeit von den Umweltbedingungen (Temperatur, Grad der Bewölkung, CO₂-Gehalt der Raumluft). Mit den Änderungen variieren oftmals nicht nur die absoluten Verbräuche, sondern auch die «Signaturen» wie etwa kleine Leistungsspitzen oder Phasenwinkel, welche zahlreichen Ansätzen als Erkennungsmerkmal dienen. Diese Variabilität und die Abweichungen vom Trainingsfall (bzw. die beim Training auftretende Unschärfe) erschwert die Geräteerkennung erheblich. Durch die umfassende Variabilität im Feld ist auch ein haushaltsspezifisches Training herausfordernd. Diese Herausforderungen bestehen auch bei NILM-Verfahren, die auf höhere Abtastfrequenzen im Kiloherzbereich zurückgreifen.

Streuung innerhalb eines Produkt-Typs: Auch innerhalb eines Produktes können Streuungen beim Verbrauch (und insbes. bei einer «Signatur») auftreten. Dies erfordert ein Training für einzelne Geräte, mit den zuvor genannten Problemen.

Abhängigkeit von der Topologie des Netzes: Greifen Ansätze auf Informationen wie Oberwellen, Phasenverschiebungen etc. zurück, wird eine zuverlässige Erkennung durch die Variabilität erschwert, die sich durch die Abhängigkeit von der Netztopologie ergibt. Konkret bedeutet dies, dass ein Computernetzteil eine andere Signatur aufweisen kann, je nachdem, in welchem Stockwerk es angeschlossen ist – oder je nachdem, ob die Stereoanlage mit Induktiver Last oder die Zimmerbeleuchtung mit Vorschaltgerät parallel dazu eingeschaltet sind. Sogar vermeintliche Nichtigkeiten wie die Lage des Nullleiters beim Einstecken des Netzsteckers können eine Rolle spielen. All dies erschwert ein stabiles Training vor Ort.

Abhängigkeit von der Versorgungsspannung: Schwankungen in der Versorgungsspannung führen zu anderen Leistungsaufnahmen. Diese zusätzliche Abhängigkeit muss beim Training berücksichtigt werden, da eine einfache Normalisierung meist nicht ausreicht.

Abhängigkeit des Einschaltzeitpunkts: NILM mit hochfrequenten Abtastungen beziehen (bezieht?) teils ein charakteristisches Einschaltverhalten mit in die Analyse ein. Dieses hängt allerdings von der augenblicklichen Höhe der Wechselspannung beim Einschalten ab, was die Anzahl der möglichen Signaturen auch bei einem einzelnen Gerät stark erhöht.

Zuordnung des Verbrauchs in eine Abtast-Periode: Bei Messungen mit einer Frequenz von 1/(15 Minuten) können Verbräuche in unterschiedliche Abtast-Perioden fallen. Dies reduziert die Möglichkeit einer Disaggregation erheblich.

Die beschriebenen Hürden lassen selbstverständlich nicht die Aussage zu, dass NILM nicht zu präzisen Ergebnissen führen kann. Dennoch sollen sie deutlich machen, dass auch ein Training auf Ebene einzelner Haushalte große Trainingsdatensätze (und damit eine enorm aufwändige Einbindung des Nutzers oder Installateurs) erfordert – schlicht wegen der Vielzahl der variablen und interdependenten Einflussfaktoren. Auch mit einer umfassenden und daher für viele Anwender kaum zumutbaren Trainingsphase bleibt die Erreichung hoher Erkennungsraten eine Herausforderung für Klassifikationsalgorithmen.



Mächtigeren Ansätze wie rekurrente neuronale Netze in Kombination mit hohen Rechenleistungen lösen das Problem aller Voraussicht nach alleine nicht, denn auch solche Verfahren benötigen bei der gegebenen Vielfalt der Fälle innerhalb einzelner Haushalte sehr große Trainingsdatensätze.

Empfehlung für weitere Forschung und Entwicklung und für eine zeitnahe Umsetzung der bestehenden Resultate in die Praxis

Eine massentaugliche Anwendung von präzisen und auf viele Geräte ausgerichtete NILM-Verfahren ist für die kommenden fünf Jahre in Haushalten nicht zu erwarten (hohe Konfidenz der Aussage). Daran ändern auch sehr hohe Rechenleistungen, wie sie vielen Forschungsprojekten bereits heute zur Verfügung stehen, und hochperformante Klassifizierer wenig.

Selbstverständlich lassen sich technische Durchbrüche nur schwer vorhersagen, allerdings scheint die Menge der erkannten Hürden für eine massentaugliche NILM-Anwendung in den vergangenen Jahren ähnlich schnell gewachsen zu sein wie die erzielten technologischen Fortschritte. Vor einer Lancierung weiterer Forschungsinitiativen im Bereich NILM sollte sowohl den Forschern als auch den Investoren/Förderinstitutionen daran gelegen sein, im Vorfeld eine besonders kritische Einschätzung der bestehenden Schwierigkeiten vorzunehmen. Insbesondere sollte eine Aussage zur Machbarkeit die hochgradige Varianz einzelner Lasten auch innerhalb einzelner Haushalte mit einbeziehen; diese erfordert haushaltsspezifische Trainingsdaten, die bisher kaum mit vertretbarem Aufwand gesammelt und (für eine Vielzahl von Schaltvorgängen) den Geräten zugeordnet werden können. Das individuelle, haushaltsspezifische Verhalten der Geräte reduziert auch den Nutzen von unkonventionellen Verfahren zur Trainingsdatenerfassung, wie z.B. mittels «Crowdsourcing-Ansätzen», bei denen die Generierung von Trainingsdaten auf vielen Schultern verteilt wird, erheblich (vgl. z.B. CAPTCHA-Techniken zum Labelling von Situationen im Strassenverkehr).

Sollen auf Basis von NILM neue Dienstleistungen zeitnah und für eine große Zahl an Haushalten angeboten werden, ist es vermutlich zielführender, einfache Use-Cases sowie Use-Cases mit hoher Fehlertoleranz zu identifizieren als auf holistische und hinreichend genaue Systeme zu hoffen. Nachfolgend sind Beispiele für praktikable NILM-Cases genannt:

Fokus auf einzelne Lasten: Anwendungen, die sich auf die Erkennung weniger (oder sogar einzelner) großer Verbraucher beschränken, sind einfacher zu realisieren. Beispiele sind Elektroautos, Wärmepumpen oder Boiler.

Fokus auf fehlertolerante Use-Cases: Anwendungen, bei denen approximative Daten einen Mehrwert bieten, können bereits viele Prozesse vereinfachen. Beispiele wären Werkzeuge für Energieberater, mit welchen diese Haushalte identifizieren, die mit hoher Wahrscheinlichkeit beraterrelevant sind. So lassen sich auch bei Schätzungen, die nur moderat besser als der Durchschnitt sind, Streuverluste reduzieren, sofern die Kosten eines Fehlers (Angebot einer Beratung, auch wenn sich die vermeintliche Wärmepumpe als Pool-Heizung herausstellt) vertretbar ist.

Fokus auf fehlertolerante Kommunikation: Die Beurteilung eines neuartigen Service durch den Endkunden hängt stark vom Erwartungsmanagement durch den Anbieter ab. Anbieter können lernen, NILM-Ergebnisse als interessanten Startpunkt einer Analyse darzustellen und Interesse an einer genaueren Analyse durch den Nutzer fördern («Haben Sie eine Wärmepumpe? Nein? Bei Ihrem Verbrauch haben wir das gedacht. Dann lohnt es sich, den Verbrauch genauer unter die Lupe zu nehmen.»).

Weitere Grundlagenforschung im Bereich NILM sollte eine besonders kritische Bewertung vorangestellt werden. Aussagen wie «neue Klassifizierer sind viel mächtiger als frühere», «es stehen heute weitaus größere Rechenleistungen zur Verfügung», oder «wir können nun mit sehr hohen Abtastraten im MHz-Bereich arbeiten» lösen das Problem der vielfältigen, interdependenten und variablen Verbrauchsmuster nicht.



Aus den drei Bereichen «Fokus auf einzelne Lasten», «Fokus auf fehlertolerante Use Cases» und «Fokus auf fehlertolerante Kommunikation» lassen sich bereits heute sinnvolle und markttaugliche Anwendungen umsetzen. Sind solche Verfahren etabliert, können auf Basis der damit gesammelten Daten schrittweise weiterführende Dienstleistungen entwickelt und getestet werden.

Die Herausforderungen sollten Energieversorger, -dienstleister und Forscher nicht davon abhalten, auch für bestehende 15-minütige Smart-Meter Daten wertstiftende Anwendungen zu entwickeln und zu erproben. Für einen zeitnahen Beitrag zur Steigerung der Energieeffizienz wäre es wichtig, Anwendungsfälle zu suchen, die sich bereits heute umsetzen lassen, anstatt auf hochperformante, allgemein anwendbare NILM-Lösungen zu warten.

Optionen für weitere Forschung und Entwicklung

Vermutlich käme der in diesem Projekt verwendete Ansatz von Kelly & Knotenbelt mit der hohen Varianz in den Haushalten besser zurecht, wenn die Menge der Trainingsdaten massiv erhöht werden könnte. Allerdings macht es wenig Sinn, selbst bei Verfügbarkeit grösserer Datenmengen damit weiter zu experimentieren, da in der Zwischenzeit eine Vielzahl von neuen vielversprechenden Ansätzen publiziert worden sind. Eine Ende 2019 durchgeführte Recherche bietet einen Überblick der im Forschungsbereich NILM seitdem veröffentlichten Publikationen mit neuen Ansätzen bzw. Algorithmen auf Basis von Deep Neural Networks:

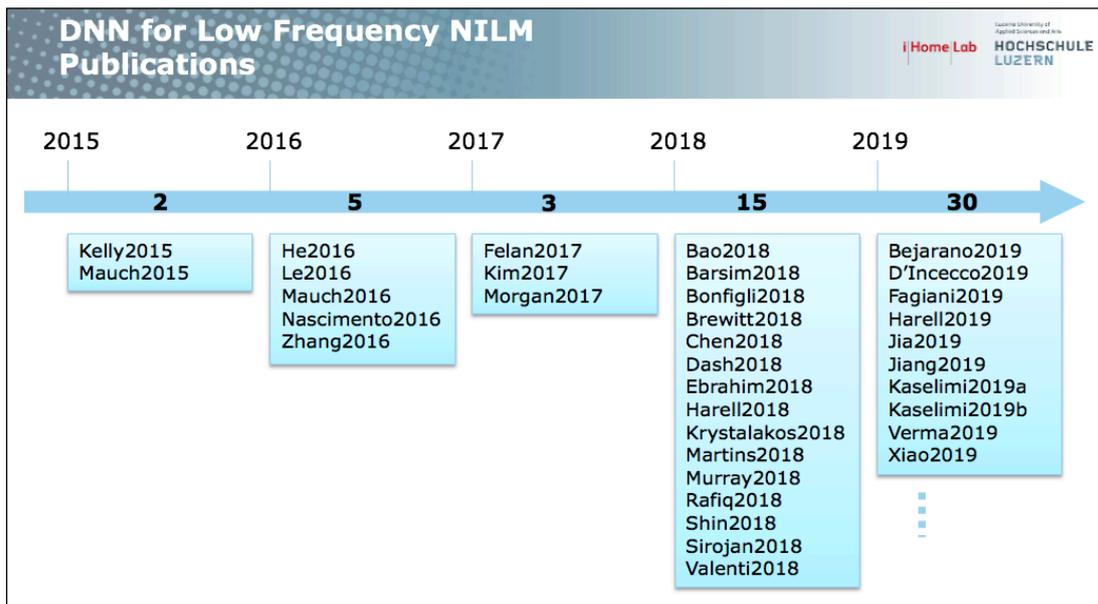


Abbildung 30: NILM-Publikationen

Als Beispiel sei hier die Publikation *Transferability of neural networks approaches for low-rate energy disaggregation* von Murray [13] genannt. Das Netzwerk klassifiziert einerseits den Zustand (on/off) der Geräte und nutzt diesen als zusätzlichen Input zur Vorhersage der Leistungsaufnahme. Der Algorithmus soll besonders gut generalisieren können und insbesondere sehr gute Resultate bei neuen, bisher ungesehenen Daten (unseen houses) liefern.



5.2 Zukünftige Umsetzung beim Projektpartner

- Das Bits to Energy Lab nutzt die Ergebnisse als Grundlage für die thematische Ausrichtung zukünftiger Arbeiten mit Smart-Meter-Daten. Der Fokus liegt fortan auf der Erkennung von größeren Verbrauchern wie Plug-In-Hybridfahrzeuge und Wärmepumpen. Weiter arbeitet das Lab an der Verbesserung der Feature-Definition für Zeitreihendaten, da die Projektergebnisse die Bedeutung einer Dimensionsreduktion verdeutlichen.
- Die HSLU wird nach Abschluss des Projektes die aggregierten Daten aufbereiten und den kompletten (anonymisierten) Datensatzes in höchstmöglicher Qualität und mit allen erforderlichen Zusatzinformationen publizieren. Damit kann der internationalen Forschergemeinde einer der grössten verfügbaren NILM-Datensätze in einem standardisierten Format [14]–[16] für die direkte Verwendung in Forschungsprojekten zur Verfügung gestellt werden.
- Mit dieser Projekterfahrung bevorzugt die EKZ aktuell Anwendungen, die auf 15-Minuten Standard Smartmeter Lastgängen basieren. Der Mehraufwand der Installation eines Smartmeter Gateways ist in der Regel zu hoch im Vergleich mit der Zahlungsbereitschaft der meisten Kunden. Die Unzuverlässigkeit der Datenverbindung, die im Normalfall über den Kundenrouter stattfinden würde, würde auch hohe zusätzliche operative Kosten verursachen. Daher fokussiert sich die EKZ auf «fehlertolerante Use-Cases», die auch mit 15-Minuten Daten realisierbar sind. Ein entsprechendes Portal für Kunden wurde eingeführt.
- Die Visualisierung von Stromverbräuchen in Echtzeit ist bei der Energie Thun AG inzwischen ein etabliertes Produkt, welches unter dem Namen STROMzeiger vertrieben wird. Das Projekt hat gezeigt, dass eine ursprünglich angedachte Weiterentwicklung Richtung Disaggregation von Verbrauchsdaten auf Basis von Algorithmen schwer umzusetzen ist. Das Produkt bleibt daher eher ein Tool für die Visualisierung der Stromflüsse. Die Einfachheit der Oberfläche und allfällige Peer-to-Peer Vergleiche sollen helfen breitere Kundengruppen damit abzuholen und so einen Beitrag zu Energieeffizienz zu leisten.



6 Nationale und internationale Zusammenarbeit

Die nationale Zusammenarbeit beschränkt sich auf die Zusammenarbeit mit den Konsortialpartnern Energie Thun, EKZ, Landis+Gyr, smart-me und dem Bits to Energy Lab. Internationale Partner sind keine involviert.



7 Literaturverzeichnis

- [1] C. McKerracher und J. Torriti, «Energy consumption feedback in perspective: integrating Australian data to meta-analyses on in-home displays», *Energy Efficiency*, Bd. 6, Nr. 2, S. 387–405, Mai 2013, doi: 10.1007/s12053-012-9169-3.
- [2] C. Fischer, «Feedback on household electricity consumption: a tool for saving energy?», *Energy Efficiency*, Bd. 1, Nr. 1, S. 79–104, Feb. 2008, doi: 10.1007/s12053-008-9009-7.
- [3] F. team, «Consumer Feedback Systems: How much energy saving will they deliver and for how long?», *EU Science Hub - European Commission*, Nov. 29, 2016.
<https://ec.europa.eu/jrc/en/publication/consumer-feedback-systems-how-much-energy-saving-will-they-deliver-and-how-long>.
- [4] J. Kelly, «JackKelly/neuralnilm_prototype». https://github.com/JackKelly/neuralnilm_prototype.
- [5] J. Kelly, «JackKelly/neuralnilm». <https://github.com/JackKelly/neuralnilm>.
- [6] J. Kelly und W. Knottenbelt, «Neural NILM: Deep Neural Networks Applied to Energy Disaggregation», *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments - BuildSys '15*, S. 55–64, 2015, doi: 10.1145/2821650.2821672.
- [7] J. Kelly und W. Knottenbelt, «The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes», *Sci Data*, Bd. 2, Nr. 1, S. 150007, Dez. 2015, doi: 10.1038/sdata.2015.7.
- [8] «EnergieSchweiz: Energieeffizienz im Haushalt, Herausgeber: Bundesamt für Energie BFE, Artikelnummer 805.902.D (2016)».
- [9] «www.horizont.net/schweiz/nachrichten/elektromobilitaet-die-schweiz-faehrt-unter-die-top-10-der-groessten-europaeischen-maerkten-180819».
- [10] «Hunt Allcott (2011), Social norms and energy conservation, *Journal of Public Economics*, 95(9-10) p.1082-95».
- [11] «Nolan et al. (2008), Normative social Influence is underdetected, *Personality and Social Psychology Bulletin*, 34(7) p913-23».
- [12] «Suche nach „non-intrusive load monitoring“ und „non-intrusive appliance monitoring“ als zusammenhängende Strings bei www.scholar.google.com am 29. Juni 2020».
- [13] D. Murray, L. Stankovic, V. Stankovic, S. Lulic, und S. Sladojevic, «Transferability of neural networks approaches for low-rate energy disaggregation», Feb. 2019, [Online]. Verfügbar unter: <https://strathprints.strath.ac.uk/66112/>.
- [14] «NILM Datasets of the European Non-Intrusive Load Monitoring (NILM) network | The aim of this site and the NILM Workshop is to bring together all the researchers that are working on the topic of energy disaggregation in both academia and industry.» <http://wiki.nilm.eu/datasets.html>.
- [15] N. Batra u. a., «NILMTK: An Open Source Toolkit for Non-intrusive Load Monitoring», *Proceedings of the 5th international conference on Future energy systems - e-Energy '14*, S. 265–276, 2014, doi: 10.1145/2602044.2602051.
- [16] «Demo Abstract: NILMTK v0.2: A Non-intrusive Load Monitoring Toolkit for Large Scale Data Sets». <https://arxiv.org/abs/1409.5908>.



8 Abbildungsverzeichnis

Abbildung 1: Dateninfrastruktur	8
Abbildung 2: Messdaten	9
Abbildung 3: Datenbankschema	10
Abbildung 4: Docker-Architektur	10
Abbildung 5: Gemessene Verbraucher in den Testhaushalten	11
Abbildung 6: On-/Off-Detektor an einem Netzkabel	12
Abbildung 7: Rohdaten des On-/Off-Detektors an einem Boiler (unten) sowie Referenzmessung mittels smart-me 3-Phasen-Zähler (oben)	13
Abbildung 8: Rohdaten des On-/Off-Detektors an einer Waschmaschine (unten) sowie Referenzmessung mittels smart-me 3-Phasen-Zähler (oben)	13
Abbildung 9: RNN Trainings-Phase	15
Abbildung 10: RNN Disaggregation	16
Abbildung 11: Design-Entwurf User Front-End	18
Abbildung 12: Übersicht Installationen - Messgeräte	19
Abbildung 13: Übersicht Installationen - On-Off Detektoren	20
Abbildung 14: Bereitstellung Rohdaten	20
Abbildung 15: GUI - Gesamtverbrauch	21
Abbildung 16: GUI - Details	21
Abbildung 17: GUI - Monatsvergleich	22
Abbildung 18: GUI - Gerätevergleich	22
Abbildung 19: Genauigkeit der Erkennung bei der Validierung am Beispiel eines Boilers (NTE = 0.13, NAD = 0.29)	24
Abbildung 20: Genauigkeit bei einem «unseen house» am Beispiel eines Boilers (NTE = 0.08, NAD = 0.46)	24
Abbildung 21: Genauigkeit der Erkennung bei der Validierung am Beispiel einer Waschmaschine (NTE = 4.76, NAD = 6.00)	25
Abbildung 22: Genauigkeit bei einem «unseen house» am Beispiel einer Waschmaschine (NTE = 1.69, NAD = 2.60)	25
Abbildung 23: Monatliches Nettohaushaltseinkommen	26
Abbildung 24: Umwelteinstellung der Befragten	27
Abbildung 25: Kategorien der erfolgten oder geplanten Optimierungsmassnahmen	28
Abbildung 26: Bewertung der Feedback-Optionen	29
Abbildung 27: Interesse an zusätzlichen Dienstleistungen	30
Abbildung 28: Bereitschaft zur Bereitstellung von Verbrauchsdaten an potentielle Energiedienstleistungsanbieter	31
Abbildung 29: Heatmap Datenausfälle	33
Abbildung 30: NILM-Publikationen	37