



Schweizerische Eidgenossenschaft
Confédération suisse
Confederazione Svizzera
Confederaziun svizra

Eidgenössisches Departement für
Umwelt, Verkehr, Energie und Kommunikation UVEK
Bundesamt für Energie BFE

Schlussbericht 02.12.2015

REALYSE

Load Recognition, Analyse and Benchmark

Auftraggeber:

Bundesamt für Energie BFE
Forschungsprogramm Elektrizitätstechnologien & -anwendungen
CH-3003 Bern
www.bfe.admin.ch

Kofinanzierung:

BKW FMB Energie AG, CH-3000 Bern
Feller by Schneider Electric, CH-8810 Horgen
Swisscom (Schweiz) AG, CH-8004 Zürich
Bush Energie GmbH / TopTen.ch, CH-7012 Felsberg

Auftragnehmer:

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

Autoren:

Andreas Rumsch, Hochschule Luzern – Technik & Architektur, andreas.rumsch@hslu.ch
Lukas Kaufmann, Hochschule Luzern – Technik & Architektur, lukas.kaufmann@hslu.ch
Paul Schmieder, Hochschule Luzern – Technik & Architektur, paul.schmieder@hslu.ch
Martin Camenzind, Hochschule Luzern – Technik & Architektur, martin.camenzind@hslu.ch
Iwan Bolzern, Hochschule Luzern – Technik & Architektur, iwan.bolzern@hslu.ch

BFE-Bereichsleiter:	Dr. Michael Moser
BFE-Programmleiter:	Roland Brüniger
BFE-Vertragsnummer:	SI/500894-01

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

Zusammenfassung

Trotz steigender Bevölkerungszahl soll mit der Umsetzung der Energiestrategie 2050 des Bundes der Energiekonsum in der Schweiz bis ins Jahr 2050 gegenüber heute deutlich sinken. Das iHomeLab der Hochschule Luzern Technik & Architektur forscht deshalb an Lösungen, welche zur Erreichung dieser Ziele beitragen.

Die ambitionierten Ziele der Energiestrategie fordern unter anderem auch Massnahmen, welche den Energiekonsum in privaten Haushalten reduzieren. Dazu verfolgen wir den Ansatz, Bewohner durch eine detaillierte Information über ihren Energieverbrauch dazu anzuregen, alte Geräte durch energieeffiziente Alternativen zu ersetzen, nicht benötigte Geräte auszuschalten und allgemein sparsamer mit der Energie umzugehen.

Um an detaillierte Information über den Energiekonsum zu kommen, verwenden wir die Methoden des sogenannten „Non-intrusive appliance load monitoring“ (NIALM). Dabei analysieren wir den gemessenen Gesamtstrom in einem Stromkreis und schlüsseln ihn so auf, dass wir auf die darin laufenden Geräte zurück schliessen können. Somit können wir den Bewohnern den Energieverbrauch pro Gerät mitteilen. Ausserdem können die Bewohner mit dieser Information sich in einem Vergleichsportal wie Topten.ch über energieeffizientere Alternativen informieren.

Während der Projektbearbeitung haben wir ein grosses Augenmerk auf die Erforschung und Weiterentwicklung der NIALM-Technologie gelegt. Wir haben ein Verfahren entwickelt, welches die Geräte aufgrund der durch sie verursachten Stromänderungen auf dem Netz erkennt. In einer ersten Stufe ordnet unser Algorithmus das Gerät einer von neun Geräteklassen zu. Gegenüber bereits erhältlichen Produkten kennt unser System diese Klassen bereits bei der Auslieferung. Damit das System noch detaillierter über das erkannte Gerät Auskunft geben kann, vergleicht das System in einer zweiten Stufe das neu erkannte Gerät mit zuvor trainierten Geräten und kann dann den genauen Typ angeben. Dieses Training muss der Bewohner mit seinen Geräten selber durchführen.

Die Ergebnisse des Projekts REALYSE haben wir im August 2015 mit einem Demonstrator an der Fachkonferenz zum Thema Energieeffizienz (EEDAL) einem internationalen Publikum vorgestellt.

Résumé

La stratégie énergétique 2050 de la Confédération prévoit une diminution significative de la consommation d'énergie en Suisse d'ici 2050 par rapport à la situation actuelle, et ce malgré l'accroissement de la population. Les recherches menées à l'iHomeLab de la Haute-École de Lucerne (Ingénierie et Architecture) participent à la recherche de solutions pour réaliser cet objectif.

L'ambitieux objectif de la stratégie énergétique 2050 nécessite, entre autres, des mesures qui réduisent la consommation en énergie des ménages. Afin d'inciter les habitants à remplacer leurs vieux appareils par des alternatives plus économes en énergie, à éteindre les appareils non utilisés et à être de manière générale plus économes en énergie, nous misons sur la sensibilisation des habitants en mettant à leur disposition des informations détaillées quant à leur consommation d'énergie.

L'acquisition de ces informations se fait au moyen de la méthode de « Non-intrusive appliance load monitoring » (NIALM), par laquelle la consommation totale de courant d'un réseau est mesurée et catégorisée de manière à déterminer les appareils actifs. Ainsi, il est possible de transmettre aux habitants la consommation de chaque appareil. Avec cette information, les habitants peuvent ensuite s'informer sur les alternatives plus économes en utilisant des comparateurs en ligne comme Topten.ch.

Le projet s'est concentré sur le développement et l'amélioration des technologies liées au NIALM. Ainsi, un procédé a été mis au point permettant de reconnaître les différents appareils sur la base des variations de courant qu'ils produisent. Dans un premier temps, l'algorithme répartit les appareils dans neuf catégories prédéfinies, une étape qui ne nécessite pas d'apprentissage. Le système peut ensuite comparer ses données avec des données collectées par apprentissage pour reconnaître les appareils exacts en question. L'apprentissage est effectué par les habitants eux-mêmes.

Les résultats du projet REALYSE ainsi qu'un démonstrateur ont été présentés à un public international lors de la conférence sur l'efficacité énergétique (EEDAL).

Summary

Despite an increasing population the state's energy strategy is to significantly reduce the energy consumption in Switzerland by 2050. The iHomeLab of the University of Applied Science Lucerne is researching solutions to meet the state's goals.

These ambitious energy goals require measures to reduce the energy consumption in private households. Our approach is to motivate residents to reduce their energy consumption by informing them about their consumption. This reduction can be achieved by replacing old appliances with more energy efficient ones, switching off unused appliances and by spending energy more economically.

We use „Non-intrusive appliance load monitoring“ (NIALM) to gather detailed information about the energy consumption. We measure and analyze the total power in an electric system and identify the responsible appliances. This enables us to show the residents their individual appliances' energy consumption. Residents can take this information and compare their appliances with alternatives on platforms such as Topten.ch.

During development we specifically focused on further developing NIALM. We have developed a system that can identify the individual appliances based on changes in the current power draw. The first step is to recognize the class of appliances responsible for the change in consumption. To recognize the appliance class, our system does not require additional training while other available systems do.

To get detailed information about an appliance of interest, the recognition algorithm has to be initially trained with the appliance in question by the resident. This resident trained algorithm only runs after the appliance class is detected and compares the input with the previously trained appliances. The results of project Realyse have been showcased in August 2015 at an international conference for energy efficiency (EEDAL).

Danksagung

Die Autoren danken dem Bundesamt für Energie (BFE) und dem gesamten Konsortium für die Finanzierung des Projekts REALYSE. Besonderer Dank geht an Roland Brüniger und Dr. Michael Moser vom BFE, Martin Bolliger von der Firma BKW, Martin Dubs von der Firma Feller, Roland Di Gregorio von der Firma Swisscom und Dr. Eric Bush von der Firma Bush Energie.

Inhalt

1	Glossar	8
2	Ausgangslage	10
3	Ziel der Arbeit	12
4	Vorgehen	13
5	Ergebnisse und Erkenntnisse	15
5.1	Systemübersicht	15
5.2	Load Disaggregation Framework	16
5.3	Datenakquisition	18
5.3.1	Blockschaltbild	18
5.3.2	Messung und Datenfluss	19
5.3.3	PCB	19
5.3.4	Kenndaten	20
5.4	Datenvorbereitung	21
5.5	Merkmalsgewinnung	22
5.5.1	Wahl der Merkmale	22
5.6	Geräteerkennung	25
5.6.1	Aufbereitung der Strommessdaten	25
5.6.2	Erkennungsalgorithmus	26
5.6.3	Ergebnisse der Geräteerkennung	29
5.7	Benchmarking	33
5.8	Demonstrator	34
5.9	Publikationen	38
5.9.1	Papers	38
5.9.2	Artikel im HK Gebäudetechnik	38
6	Diskussion & Erkenntnisse	39
6.1	Mehrwert für den Benutzer	39
6.2	Beitrag zur Umwelt	39
6.3	Erkenntnisse	39
6.3.1	Vorteile der zweistufigen Geräteerkennung	39
6.3.2	Vorteil der Wahrscheinlichkeit in der Erkennung	40
6.3.3	Herausforderungen der Geräteerkennung	40
6.3.4	Herausforderungen der Datenauswertung	41
6.4	Andere Projekte und Produkte	43
6.4.1	Smappee	43
6.4.2	Neurio	44
6.4.3	Universität Trier	44
7	Schlussfolgerungen & Ausblick	45
7.1	Schlussfolgerungen	45
7.2	Ausblick	45
7.2.1	Showcase im iHomeLab	45

7.2.2	P&D Projekt	46
8	Referenzen.....	47

Abbildungsverzeichnis

Abbildung 1:	Energiesparpotentiale in Haushalten nach Armel [3].	10
Abbildung 2:	Funktionsprinzip REALYSE	12
Abbildung 3:	Systemarchitektur mit Server bei einem Dienstleister.	15
Abbildung 4:	Load Disaggregation Framework	16
Abbildung 5:	Blockschaltbild Messsystem	19
Abbildung 6:	Übersicht Hardware Messsystem	20
Abbildung 7:	Berechnung der Deltakurve	21
Abbildung 8:	Durchschnittliche Dauer für die Berechnung der Parameter	24
Abbildung 9:	Ein trainierter BFTree.	29
Abbildung 10:	Ausschnitt aus der topten.ch-Webseite, hier am Beispiel von LED-Leuchtmitteln [5]. ..	33
Abbildung 11:	Darstellung der TopTen-Datenbank im Demonstrator.	33
Abbildung 12:	REALYSE-Demonstrator.....	34
Abbildung 13:	Startbildschirm Demonstrator.....	35
Abbildung 14:	Geräte-Ansicht mit nur einem Gerät	35
Abbildung 15:	Elemente der Geräte-Ansicht.....	36
Abbildung 16:	Geräte-Ansicht mit mehreren Geräten	36
Abbildung 17:	TopTen-Ansicht, hier am Beispiel des PC-Monitors	37
Abbildung 18:	Reale und „gemessene“ Leistungsaufnahme Drucker.....	41
Abbildung 19:	Realer und berechneter Energiekonsum Drucker.....	42

Tabellenverzeichnis

Tabelle 1:	Arbeitspakete des Projekts REALYSE	13
Tabelle 2:	Bewertung der Sensoren mittels gewichteten Eigenschaften.	18
Tabelle 3:	Kenndaten der Messschaltung	20
Tabelle 4:	Auflistung der untersuchten Parameter	22
Tabelle 5:	Attribut Selektion unter Information Gain Betrachtung.....	23
Tabelle 6:	Der Datensatz zur Entwicklung von NIALM.	25
Tabelle 7:	Die Datensatzkonfigurationen basierend auf Merkmalen.	25
Tabelle 8:	In REALYSE vordefinierte Geräteklassen.....	26
Tabelle 9:	Die getesteten Algorithmen, ihre Fähigkeiten und Herkunft.....	27
Tabelle 10:	Der Template Matcher und der BFTree getestet mit dem Rohdatensatz	30
Tabelle 11:	Testergebnisse einer Auswahl der getesteten Algorithmen.	30
Tabelle 12:	Ergebnisse der Tests mit dem Template Matcher und verschiedenen Formen der Eingabedaten.	31

1 Glossar

6LoWPAN	IPv6 over Low power Wireless Personal Area Network: Funkprotokoll
AC	Alternate Current: Wechselstrom/-spannung
ADC	Analog to Digital Converter: Analog-Digital Umsetzer
AES	Advanced Encryption Standard: Blockchiffre zur Verschlüsselung von Daten.
AES-128	128-bit AES-Verschlüsselung
BFE	Bundesamt für Energie
BFTree	Best-First Decision Tree: Erkennungsalgorithmus in Form eines binären Entscheidungsbaums
CFL	Compact Fluorescence Light: Stromsparlampe
DC	Direct Current: Gleichstrom/-spannung
DCO	DC Offset: Mittelwert eines AC-Signals
DSP	Digital Signal Processor: Speziell für die digitale Signalverarbeitung ausgelegter Prozessor.
EEDAL	Energy Efficiency in Domestic Appliances and Lighting: Internationale Konferenz
ENOB	Effective Number of Bits: Tatsächlich verwendbare Anzahl von Bits einer Analog-Digital-Umsetzung
FL	Fluorescence Light: Fluoreszenz Lampe
<i>Hall-Sensor</i>	Sensor, welcher den Stromfluss in einem Leiter kontaktlos anhand des im Leiter induzierten Magnetfeldes misst.
LED	Light Emitting Diode: Leuchtdiode
LibSVM	Source-Code Bibliothek von Machine-Learning-Algorithmen
LoReMA	Load Recognizing Meter and Actuator: Vorgängerprojekt von RELAYSE
<i>Machine Learning</i>	Maschinelles Lernen: Oberbegriff für die künstliche Generierung von Wissen aus Erfahrung.
MIT	Massachusetts Institute of Technology
NIALM	Non-Intrusive Appliance Load Monitoring
P	Effektive Leistung
PFC	Power Factor Correction: Verfahren um den stossartigen Stromverlauf von Schaltnetzteilen auf die gesamte Periodenlänge zu verteilen.
Q	Blindleistung
RMS	Route Mean Square: Effektivwert von Strom/Spannung
<i>Rogowski-Spule</i>	Ein auf dem Prinzip der elektromagnetischen Induktion basierender Stromsensor.
<i>Shunt-Widerstand</i>	Ohm'scher Widerstand, welcher für die Strommessung eingesetzt wird.
SNDR	Signal to Noise plus Distortion Ratio: Misst die Reinheit eines Signals. Verhältnis der Signalleistung zur totalen Rausch- und Verzerrungsleistung
SNR	Signal to Noise Ratio: Verhältnis zwischen Nutzsignal und Rauschen, angegeben in dB.
SRAM	Static Random-Access Memory
<i>Stromtransformator</i>	Stromsensor für Wechselströme der auf dem Prinzip der elektro-

	magnetischen Induktion basiert.
<i>Template</i>	Muster. Im Fall von REALYSE eine Stromkurve eines Geräts.
<i>Template Matcher</i>	Erkennungsalgorithmus, welcher Templates von unbekannten Geräten mit Templates von bekannten Geräten vergleicht.
THD	Total Harmonic Distortion: Verhältnis der summierten Leistungen aller Oberschwingungen zur Leistung der Grundschiwingung
VSE	Verband Schweizerischer Elektrizitätsunternehmen
WAN	Wide Area Network: „Internet“
Web-API	Application Programming Interface (Programmierschnittstelle) für Webserver oder Webbrowser.
WEKA	„Waikato Environment for Knowledge Analysis“: Source-Code Bibliothek von Machine-Learning-Algorithmen.

2 Ausgangslage

Das Bundesamt für Energie (BFE) beschreibt in der Energiestrategie 2050 [1] drei verschiedene Szenarien über den künftigen Energiekonsum der Schweiz. Das Szenario „Massnahmen Bundesrat“ zum Beispiel sieht eine Reduktion des nationalen Energiekonsums von heute über 880PJ pro Jahr auf 565PJ im Jahre 2050 vor. Die beiden anderen Szenarien rechnen mit einem weniger bzw. noch stärker reduzierten Energieverbrauch bis 2050.

Unabhängig davon welches Szenario verfolgt wird, sind Massnahmen erforderlich, um diese Energiesparziele zu erreichen. Der Verband Schweizerischer Elektrizitätsunternehmen (VSE) schlägt in seinem Bericht [2] daher mehrere Wege für eine Reduktion des Energiekonsums vor. Dazu zählen:

- Geräte austauschen durch effizientere Geräte
- Geräte bei Nichtbedarf automatisch ausschalten
- Konsumenten durch Anzeige des Stromverbrauchs zu mehr Sparsamkeit anregen

Das VSE sieht eine Reduktion des Stromverbrauches von 3% durch das alleinige Anzeigen des Gesamtverbrauches durch Smart-Meter. Eine detailliertere Analyse zeigte Armel in ihrer Publikation [3]. Sie vergleicht Arten von Feedbacksystemen im Bereich des elektrischen Energieverbrauchs. Als Resultat entstand Abbildung 1. Alleine durch eine verbesserte Rechnung könne 3.8% Energie gespart werden. Das Sparpotential von Real-Time Systemen ohne Aufschlüsselung sieht sie im Bereich von 9.2%. Eine Aufschlüsselung der Geräte ermögliche sogar 12% Energiesparpotential.




Abbildung 1: Energiesparpotentiale in Haushalten nach Armel [3].

Für die Aufschlüsselung des elektrischen Energieverbrauchs ist ein entsprechendes Messsystem erforderlich. Ein dezentrales Messsystem für die Erfassung des Energieverbrauchs der einzelnen Geräte erfordert jedoch einen hohen Installationsaufwand, weshalb alternative Methoden gefragt sind.

Eine davon ist das „Non-Intrusive Appliance Load Monitoring“ (NIALM). Dies ist eine Methode die eingesetzt werden kann, um Informationen über den Energieverbrauch einzelner Geräte an einer zentralen Position zu erheben. Als Eingangsgrössen verwendet ein NIALM System die Stromverbrauchswerte mehrerer Geräte in Form einer Summenkurve. Da jedes Gerät einen charakteristischen Stromverbrauch aufweist, kann aus theoretischer Sicht diese Summenkurve in die Stromverbrauchskurven der einzelnen Geräte aufgeschlüsselt werden.

Die ersten NIALM Systeme wurden Anfang der 90er in den USA am Massachusetts Institute of Technology (MIT) unter Federführung von George W. Hart entwickelt. Die Lasterkennung von Hart basierte damals auf der Erkennung der stationären Zustandswechsel während den Ein- und Ausschaltphasen von Endgeräten. In den vergangenen Jahren wurden weitere Verfahren zur Identifikation entwickelt.

Dank leistungsfähigeren Mikrocontrollern ist es heute möglich, komplexe Merkmale aus der gemessenen Summenkurve zu extrahieren und diese mit rechenintensiven maschinellen Lernverfahren zu kategorisieren. Dies eröffnet neue Möglichkeiten in der Erkennung der Verbraucher und erhöht die Treffsicherheit der NIALM Algorithmen.

Ein NIALM System kann eine Energiereduktion in allen vom VSE aufgezählten Punkten erreichen. Werden zum Beispiel Glühbirnen im Gesamtverbrauch erkannt, kann ein Benutzertipp deren Austausch vorschlagen oder die Glühbirne bei Abwesenheit des Benutzers automatisch ausschalten. Benutzer können auch durch die Darstellung des Energieverbrauchs dieser Glühlampe auf deren Verbrauch sensibilisiert werden.

3 Ziel der Arbeit

Das Projekt REALYSE hat zum Ziel zu zeigen, dass mit der NIALM-Technologie die einzelnen in einem Haushalt betriebenen Geräte erkannt und dadurch dem Benutzer detaillierte Informationen über seinen Energieverbrauch gegeben werden können. So soll auch der Energieeffizienzindex der Geräte bestimmt und falls sinnvoll auf alternative Geräte mit einer besseren Energieeffizienz hingewiesen werden. Dies soll anhand der auf dem Vergleichsportal TopTen.ch zur Verfügung gestellten Daten realisiert werden.

Die Herausforderung im Projekt besteht in der präzisen Erkennung der Geräte, so dass diese mit anderen Geräten derselben Kategorie verglichen werden können. Am Beispiel des Bildschirms stellt sich die Frage nach Bildschirmgröße und Bildschirmtechnologie, damit ein realistischer Vergleich erfolgen kann. Durch Einbinden des Vergleichsportals TopTen.ch bekommt das Projekt einen starken gesellschaftlichen Bezug. Denn neben der Effizienzbestimmung soll die Energieeffizienz von Geräten in künftige Kaufentscheide einbezogen werden.

Anhand der folgenden Grafik ist erklärt, wie ein solches NIALM System aufgebaut sein könnte.




Abbildung 2: Funktionsprinzip REALYSE

Einer oder mehrere Messadapter (2) sind in der Testumgebung installiert. Die Testumgebung kann ein Büro oder Haushalt sein. Die Messadapter messen die angeschlossenen Lasten (1) permanent und detektieren dabei jede Lastveränderung. Eine Lastveränderung geschieht in der Regel durch ein- oder ausschalten von Verbrauchern. Natürlich gibt es auch dynamische Lasten die z.B. mehrere Betriebszustände haben oder ganz variabel im Verbrauch sind und auf diese Weise eine Lastveränderung erzeugen. Erfolgt eine Lastveränderung erkennt dies der Messadapter, worauf hin eine vollständige Messung der neuen Last durchgeführt wird. Die Messwerte (3) werden an eine Zentrale (5) zur Analyse übertragen. In der Analysephase wird zuerst ein Geräteinventar der Testumgebung erstellt um in einem zweiten Schritt die Laständerung dem jeweiligen Gerät zuzuordnen. Primäres Ziel ist es die Endgeräte mittels Softwarealgorithmen zu erkennen. Gelingt dies nicht, muss eine Möglichkeit geboten werden, mit ergänzenden Fragen das Gerät zu bestimmen. Ergänzende Fragen sind auch zulässig um die Geräte genauer zu bestimmen, so soll bei einem Kühlschrank der Volumeninhalt erfragt werden können. Ist das Gerät einmal bestimmt wird es in der Fingerprint-Datenbank gespeichert. Danach erfolgt der Benchmark-Teil. Dazu werden Benchmark-Werte zu den gerätespezifischen Energieetiketten im Internet bezogen (4) und so das Geräteinventar beurteilt. Im „Best in Class“ Teil werden aus einem Benchmark-Portal die besten/effizientesten Ersatzgeräte gesucht (6) und dem Benutzer vorgeschlagen. Der Benutzer bekommt durch REALYSE einen Überblick über die Effizienz seines Geräteinventars.

4 Vorgehen

Das Projekt REALYSE baut auf den Ergebnissen des Vorgängerprojekts LoReMa (Load Recognizing Meter and Acuator) auf. In mehreren Phasen haben wir die Algorithmen und das Messsystem weiterentwickelt und verbessert. Für das Projekt haben wir mehrere Arbeitspakete definiert und abgearbeitet. Diese sind in Tabelle 1 aufgelistet und beschrieben.

An der Konferenz für "Energy Efficiency in Domestic Appliances and Lighting" (EEDAL) 2015 haben wir das Projekt mit der Präsentation von zwei Papers und einem Demonstrator einem internationalen Publikum aus Fachkreisen vorgestellt. Nach Abschluss des Projekts präsentieren wir die Ergebnisse als Showcase den Besuchern im iHomeLab.

Tabelle 1: Arbeitspakete des Projekts REALYSE

Arbeitspaket	Inhalt
WP1: NIALM Community	Die iHomeLab Kontakte zur jüngst gegründeten NIALM Community sind zu intensivieren. Im Rahmen des Projektes wird geprüft, welche neuen Erkenntnisse in der Community gewonnen worden sind. Gibt es neue Verfahren oder wurden neue Algorithmen entworfen? Wurden bereits Datensets definiert? Gibt es eine Datenbank mit Device Fingerprints und ist diese allgemein zugänglich.
WP2: Weiterentwicklung des Messsystems und der Erkennungsalgorithmen	Es ist zu prüfen, welche Messwerte generiert werden müssen, um die Endgeräte treffsicher zu erkennen. Denn mit REALYSE soll es möglich sein, anhand der Geräte-Signatur das Endgerät zu erkennen und so zwischen PC, TV und anderen elektronischen Verbrauchern zu unterscheiden. Zusätzlich sind die Resultate des Projektes „iSmart: Ergänzungsprojekt Geräteerkennung“ in die Arbeiten von REALYSE einzubeziehen. Die Unterscheidung von verschiedenen elektronischen Verbrauchern ist sehr anspruchsvoll. Meist handelt es sich um getaktete Netzteile, die untereinander eine sehr ähnliche Signatur aufweisen. Im Rahmen dieses Forschungsprojektes ist zu prüfen, welche zusätzlichen Verfahren für die eindeutige Erkennung der Endgeräte zur Anwendung kommen. In einem früheren vom BFE unterstützten Projekt (LoReMa) konnten erste Grundsteine für die Geräteerkennung gelegt werden. Diese Grundlagen sind zu prüfen und zu erweitern. Gelingt eine eindeutige Erkennung des Endgerätes nicht, so sind Alternativen und/oder Zusatzinformationen zu erheben. Zum Beispiel ist ein Lernprozess mit Userunterstützung denkbar.
WP3: Messsystem und Gesamtsystemintegration	Das Messsystem wird in einer Kleinserie gefertigt und für das Gesamtsystem bereitgestellt. Das REALYSE Messsystem muss mit der REALYSE Zentrale kommunizieren, denn das Messsystem muss die Messwerte zur Auswertung an die Zentrale übertragen. Es kann die LoReMa ZigBee Kommunikation zur Anwendung kommen oder auch 6LoWPAN. Das Messsystem und die Zentrale werden zu einem Gesamtsystem zusammengeführt.
WP4: Grundlagen einer Fingerprint Datenbank	Im Projekt wird ein Datenbankmodell für die Fingerprint-Daten entwickelt. Dieses wird mit den im Projekt generierten Messwerten abgefüllt. Ein Daten-Set mit allen relevanten Werten für die Geräteerkennung muss definiert werden. Erstmals werden die Fingerprint-Daten in einer zentralen Datenbank abgelegt, damit ähnliche Verbraucher besser identifiziert werden können. Sinnvollerweise wird im Daten-Set auch die Energieeffizienz und die Geräte-Klasse beschrieben. So lassen sich die identifizierten Geräte schnell beurteilen.
WP5: Quellen für Effizienz und „Best in Class“ bestimmen und anbinden	Quellen für Effizienzinformationen von Endgeräten Wichtig in REALYSE ist die Bestimmung der Geräteeffizienz. Im Rahmen des Projektes muss eine Quelle für die Geräteeffizienz gefunden werden damit eine genaue Beurteilung erfolgen kann. Alternativ dazu kann auch ein Referenzwert zu den „Best in Class“ Produkten generiert werden. Anbindung an ein Benchmark-Portal z.B. TopTen.ch Ein Bestandteil von REALYSE ist der Link zu den „Best in Class“ Geräten. Ist das Endgerät richtig identifiziert, soll diesem das Beste seiner Klasse gegenüber gestellt werden. So soll das Energiesparpotential im Fall eines Austausches aufgezeigt werden. Wünschenswert ist der Link zu TopTen.ch dem Schweizer Produkte Vergleichsportal.

WP6: EEDAL, iHomeLab ShowCase und Schlussbericht	Paper und Präsentation an der EEDAL REALYSE soll in Fachkreisen präsentiert werden. Die Resultate werden mit einem Paper an der EEDAL "Energy Efficiency in Domestic Appliances and Lighting" 2015 eingereicht und wenn möglich präsentiert. ShowCase im iHomeLab Auf Basis der LoReMA Hardware wird ein Showcase erarbeitet, der die smarte Geräteerkennung für Besucher des iHomeLab erfahrbar macht.
---	---

5 Ergebnisse und Erkenntnisse

5.1 Systemübersicht

Die Architektur des REALYSE-Gesamtsystems ist in Abbildung 3 grafisch dargestellt. Zu sehen ist, dass die Messung der erforderlichen Parameter – also Strom und Spannung – im Elektroverteiler eines Haushalts mittels mehrerer Messsysteme erfolgt. Geplant ist mindestens ein Messsystem pro Phase (L1, L2, L3), idealerweise aber ein Messsystem pro abgesicherten Stromkreis. Per Kommunikationsbus werden die akquirierten Daten an ein Analysesystem übertragen, wo die Ereigniserkennung, die Erkennung der Verbraucherklasse sowie des Verbrauchers selbst stattfindet.

Das Analysesystem ist über WLAN oder Ethernet mit dem lokalen Netzwerk verbunden. So können die Ergebnisse der Analyse zusammen mit den dazu gehörigen Leistungsdaten (in Watt) lokal abgefragt oder an einen Server weitergeleitet werden. In der Abbildung befindet sich dieser Server bei einem Anbieter des REALYSE-Systems (Systemanbieter). Alternativ könnten die Daten auch lokal im Analysesystem oder in einem lokalen Server gehalten werden, falls ein solcher vorhanden ist.

Auf dem Server werden die Daten für die Visualisierung auf einem PC, Laptop oder Mobilgerät aufbereitet. Ebenfalls auf dem Server wird die Anbindung an das Vergleichsportal TopTen.ch realisiert.




Abbildung 3: Systemarchitektur mit Server bei einem Dienstleister.

Im Projekt REALYSE haben wir ein System mit einem lokalen Server realisiert. Dies ist einfacher zu implementieren und reicht für die Labortest vollkommen aus. In einem System im realen Umfeld macht aber die Verwendung eines zentralen Servers bei einem Dienstleister durchaus Sinn, da sich dadurch der Benutzer einerseits nicht selbst um die Datenverwaltung kümmern muss und andererseits ein gesicherter Zugriff auf die Daten von einem beliebigen Punkt im WAN erfolgen kann.

5.2 Load Disaggregation Framework

Im WP1 wurde das sogenannte „Load Disaggregation Framework“ entworfen. Dieses fasst die verschiedenen Prozesse von der Datenakquisition bis zum Output, also den aufgeschlüsselten Energiedaten, zusammen und zeigt, welche Methoden in den verschiedenen Prozessen angewendet werden können. In Abbildung 4 ist eine grafische Darstellung des „Load Disaggregation Frameworks“, wie es in REALYSE verwendet wurde, zu sehen.




Abbildung 4: Load Disaggregation Framework

Folgend werden die einzelnen Prozesse und die für REALYSE verwendeten Elemente kurz erklärt. In den weiteren Abschnitten dieses Kapitels wird dann detailliert erläutert, wie die Prozesse für REALYSE umgesetzt wurden. Eine ausführlichere Beschreibung der einzelnen Prozesse und Elemente ist der Dokumentation zum Arbeitspaket 1 zu entnehmen [4].

Datenakquisition

Der erste Prozess umfasst die Akquisition der für die Lasterkennung erforderlichen Daten. Dies können sowohl Netzspannung oder Netzstrom, aber auch Messwerte aus der Umgebung wie z.B. die Temperatur oder die Zeit sein. Diese Daten werden entweder vom System selbst generiert oder von einem übergeordneten System erhalten.

Die Schnittstelle zum nachfolgenden Prozess bilden die akquirierten Daten in unverarbeiteter Form (Rohdaten).

Für REALYSE wird der in den abgesicherten Stromkreisen fließende Strom verwendet. Die Spannung wird ebenfalls gemessen, jedoch lediglich zur Detektion des Nulldurchgangs verwendet. So kann der Strom jeweils für genau eine Periode der Netzfrequenz gemessen werden. Für die Akquirierung der Stromdaten wird ein speziell dafür entwickeltes, hochpräzises Messsystem verwendet (siehe Abschnitt „5.3 Datenakquisition“).

Datenvorbereitung

Der Prozess der Datenvorbereitung nimmt die Rohdaten der Sensoren auf und bereitet sie für die Verarbeitung der nachkommenden Prozesse vor. Ziel dieses Prozesses ist einerseits das Filtern von

Störsignalen. Andererseits wird eine erste Selektion und Vorverarbeitung der Datenmenge vorgenommen.

Bei REALYSE werden die Daten periodisch akquiriert und als Deltakurve weitergeleitet. Konkret wird einmal pro Sekunde die Stromkurve für eine Periode der Netzfrequenz gemessen und danach die Differenz, also die Deltakurve zu einer vorher gemessenen Stromkurve, errechnet.

Details dazu sind dem Abschnitt „5.4 Datenvorbereitung“ zu entnehmen.

Merkmalsgewinnung

Für die Gewinnung der Merkmale können die vom vorangehenden Prozess vorbereiteten Daten so belassen oder umgeformt und/oder in andere Bereiche wie den Frequenzbereich abgebildet werden.

In REALYSE war geplant, dass die Schnittstelle vom Prozess der Merkmalsgewinnung zum nachfolgenden Prozess gleichzeitig die physikalische Schnittstelle zwischen dem Messsystem und dem Analysesystem darstellen sollte. Dies ist ein Grund, weshalb die Daten ursprünglich auf den sogenannten Feature-Vektor reduziert wurden. Dieser besteht aus den Werten von Wirk- und Blindleistung (P und Q), sowie aus den ungeraden harmonischen Schwingungen bis zur elften, gewonnen durch die Fourier-Transformation der Stromdaten.

Im aktuellen Ansatz werden direkt die Deltakurven im Zeitbereich als Merkmal verwendet. So ist zwar die verwendete Datenmenge sehr gross, es gehen aber keinerlei Informationen durch Umformung oder Abbildung verloren.

Im Abschnitt „5.5 Merkmalsgewinnung“ wird näher darauf eingegangen.

Geräteerkennung

Die Aufgabe dieses Prozesses ist die Erkennung der Verbraucher basierend auf den vom vorhergehenden Prozess erhaltenen Daten unter Zuhilfenahme der Daten von Referenzgeräten.

Im ersten Ansatz wurde dafür ein binärer Entscheidungsbaum (BFTree) verwendet, welcher aufgrund der Daten der Referenzgeräte erstellt wurde. Für die Identifikation wurden die Daten aus dem erwähnten Feature-Vektor verwendet.

Im aktuellen Ansatz wird der Template Matcher (TM) verwendet, welcher mit den Stromkurven arbeitet. Dieser ist in der ursprünglichen Fassung des „Load Disaggregation Frameworks“ zwar nicht enthalten, hat sich aber als zuverlässigstes Verfahren zur Erkennung von Ereignissen und Verbrauchern entpuppt. Details dazu sind im Abschnitt „5.6 Geräteerkennung“ zu finden.

Die Ausgabe dieses Prozesses ist eine Liste aller Verbraucher, inklusive der dazugehörigen momentanen Leistungsaufnahmen.

Energieberechnung

Eine Variante, wie die Daten der Lastaufschlüsselung weiter verwendet werden können, ist die Berechnung der pro Verbraucher konsumierten Energie. Hierzu muss die Leistung der einzelnen Verbraucher über die Zeit integriert werden.

In REALYSE haben wir die Berechnung der Energie derzeit noch nicht umgesetzt, da hierfür eine kontinuierliche Aufnahme des Lastgangs pro Gerät vorausgesetzt wird. Die Problematik dahinter wird im Abschnitt „6.3.4.1 Bestimmen des Energiekonsums“ beschrieben.

Benchmarking

Die aus der Verbrauchererkennung gewonnen Informationen können für weitere Auswertungen verwendet werden.

In REALYSE werden die erkannten Verbraucher mit Verbrauchern derselben Kategorie verglichen, welche besonders Energieeffizient sind. Dies geschieht durch die Anbindung des Systems an die Datenbank von TopTen.ch. Eine detaillierte Beschreibung dazu ist im Abschnitt „5.7 Benchmarking“ zu finden.

5.3 Datenakquisition

Für die Datenakquisition haben wir eine auf die Anforderungen spezialisierte Hardware entworfen, welche die Netzspannung sowie den Laststrom mit hoher Auflösung und möglichst geringen Eigenverlusten abtastet. Für eine optimale Lasterkennung soll der Laststrom mit einer Auflösung von minimal 15 Bit ENOB bei einer Bandbreite grösser 1.2kHz abgetastet werden. Da jegliche Nichtlinearitäten zu Verzerrungen führen, welche die nachfolgenden Analysealgorithmen beeinträchtigen, haben wir verschiedene Strommessprinzipien wie Hall-Sensoren, Stromtransformatoren, Shunt-Widerstände sowie Rogowskispulen auf ihre Eignung untersucht. Kernparameter bei der Evaluation waren Linearität, Empfindlichkeit, Messbereich, Verlustleistung und weitere.

Tabelle 2 zeigt das Resultat der Auswertung anhand der gewichteten Eigenschaften der einzelnen Sensoren. Es zeigte sich, dass der Shunt-Widerstand das für diese Anwendung idealste Messprinzip darstellt. Konkret haben wir einen Widerstand der Grösse von 20mΩ ausgewählt da dieser einen guten Kompromiss zwischen Leistungsverlusten und notwendiger Verstärkung bildet. Ausgehend von dieser Wahl des Messprinzips wurden alle weiteren Komponenten des Messsystems evaluiert.

Tabelle 2: Bewertung der Sensoren mittels gewichteten Eigenschaften.

Sensoren	Kosten	Bandbreite	Messbereich	Präzision	Temperaturdrift	Isolation	Offset	Verlustleistung	DC?	Empfindlichkeit	Hysteresis	Linearität	Grösse	Summe	Rang
Gewichtung	6	9	11	8	7	1	2	10	4	12	4	13	6		
Shunt	2	2	2	1	1	0	0	1	2	1	2	2	2	143	1
CT	1	2	1	1	2	2	2	2	0	2	0	1	1	126	3
Rogowski	2	2	0	1	2	2	2	2	0	1	2	2	0	124	4
Hall	0	2	0	1	1	2	0	2	2	1	0	0	0	75	8
AMR	0	2	0	1	1	2	0	2	2	0	0	1	1	82	6
GMR	1	2	2	0	0	2	0	2	2	0	0	1	1	95	5
GMI	1	2	0	1	1	2	0	0	2	0	2	1	2	82	6
Flux-gate	0	2	2	2	2	2	2	1	2	1	0	2	1	138	2

5.3.1 Blockschaltbild

In Abbildung 5 ist das abstrahierte Blockschaltbild der wichtigsten Komponenten des Messsystems aufgezeigt. Die Hardware ist für den Einsatz im 230V AC-Netz ausgelegt und besitzt entsprechende Schutzmechanismen gegen Überspannungen in den Eingangsstufen. Wie erwähnt, wird für die Erfassung des Laststroms ein Shunt-Widerstand von 20mΩ eingesetzt. Hiermit lassen sich Lastströme von bis zu 10 A_{RMS} (2300W) zuverlässig verarbeiten und mit grösstmöglicher Linearität digitalisieren. Die Netzspannung wird mittels eines einfachen Spannungsteilers erfasst.




Abbildung 5: Blockschaltbild Messsystem

In der Signalaufbereitung werden die Eingangsspannungen entsprechend des Eingangsbereichs der nachfolgenden Analog-Digital Umsetzung verstärkt. Eine zusätzliche Filterung mit einem Tiefpassfilter 3. Ordnung (-3db Grenzfrequenz bei 13kHz) minimiert Aliasing-Effekte von hochfrequenten Störungen.

Eines der wichtigsten Elemente der Schaltung ist der ADC, welcher das Analogsignal des Stromsensors digitalisiert. Aus einer Auswahl von 150 ADC wurde der ADS1255 von Texas Instruments ausgewählt. Dieser 24Bit-ADC zeichnet sich durch sein geringes Eigenrauschen und eine hohe Linearität aus. Ein programmierbarer Eingangsverstärker ermöglicht die zusätzliche Verstärkung des analogen Eingangssignals für eine Erweiterung des Dynamikbereiches bei kleineren Lastströmen.

Für die Verarbeitung und Weiterleitung der Daten ist ein Mikrocontroller der Familie STM32F303 von ST Microelectronics verantwortlich. Dieser besitzt einen ARM Cortex M4 Prozessorkern. Das eingesetzte Derivat verfügt über 256kB Flash, 40kB SRAM sowie über umfangreiche DSP-Funktionalitäten.

5.3.2 Messung und Datenfluss

Die durch den Strom am Shunt-Widerstand verursachte Spannung wird nach der Filterung und Aufbereitung vom ADC mit einer Frequenz von 7.5kHz abgetastet und mit 24Bit quantisiert. Gleichzeitig wird die Netzspannung über einen Spannungsteiler in einen für das System messbaren Bereich geteilt. Dieses Signal wird vom ADC des Mikrocontrollers mit 12Bit quantisiert und dazu verwendet, den positiven Nulldurchgang der Netzspannung zu detektieren.

Einmal pro Sekunde werden für die Dauer einer Periode der Netzfrequenz (20ms) vom Mikrocontroller die digitalisierten Strommesswerte des ADS1255 abgefragt. Um den Beginn einer Periode zu bestimmen, wird der Nulldurchgang der Netzspannung verwendet.

Mit dieser Messung erhält man eine Messkurve mit 150 24-Bit-Messwerten, welche dann über die serielle Schnittstelle an das Analysesystem weitergeleitet wird.

5.3.3 PCB

Das fertige Messsystem ist in Abbildung 6 dargestellt. Es lässt sich grob in einen analogen Teil (links) und einen digitalen Teil (rechts) unterteilen. Im linken Teil sind der Shunt-Widerstand, die Referenzspannungen, der Überspannungsschutz sowie die differenzielle Verstärkerschaltung und der ADC zu sehen, in der rechten Hälfte befinden sich die Spannungsversorgung, der Mikrocontroller sowie die serielle Schnittstelle. Das Layout besteht aus 4 Lagen, wobei je eine als Versorgungsspannung und Ground ausgeführt wurden.




Abbildung 6: Übersicht Hardware Messsystem

5.3.4 Kenndaten

Die wichtigsten Kenndaten des Messsystems sind in Tabelle 3 zusammengefasst. Das SNR von über 100dB sowie das THD von -100dB bestätigen die hohe Auflösung sowie Linearität des Messsystems. Das Ziel von 15Bit ENOB wird damit übertroffen.

Tabelle 3: Kenndaten der Messschaltung

Parameter	Wert	Einheit
Datenrate	7500	Hz
Messungen pro Sekunde	1	Hz
Auflösung	24	Bit
ENOB	15.9	Bit

Parameter	Wert	Einheit
SNR	101	dB
THD	-100	dB
SNDR	98	dB
Leistungsaufnahme	89	mW

5.4 Datenvorbereitung

Die Datenvorbereitung findet auf dem Analysesystem statt und hat zum Ziel, die vom Messsystem erhaltenen Rohdaten so vorzubereiten, dass die Treffsicherheit der Erkennungsalgorithmen maximal wird.

Die Rohdaten stellen immer eine Summenkurve aller angeschlossenen Verbraucher dar. Wird diese direkt für die Verbrauchererkennung verwendet, steigt die Anzahl zu erkennender Zustände N_M exponentiell, da alle einzelnen Gerätezustände in verschiedenen Kombinationen vorkommen können.

Unter der Annahme, dass alle N Verbraucher nur einen Verbraucherzustand haben und maximal K Verbraucher zur selben Zeit betrieben werden, kann die Anzahl möglicher Kombination an verschiedenen Zuständen der Summenkurve mit folgender Formel aus der Kombinatorik berechnet werden. Dabei wird berücksichtigt, dass ein Verbraucher mehrmals gleichzeitig vorkommen kann:

$$N_M = \binom{N + K}{K} \quad \text{Formel 1}$$

Einerseits ist es sehr aufwändig alle Messkurven für diese grosse Anzahl Möglichkeiten zu erfassen, damit die Algorithmen auf diese trainiert werden können. Andererseits wird es kaum möglich sein diese hohe Anzahl mit Algorithmen zuverlässig zu trennen.

Daher werden Verfahren verwendet, welche die Anzahl der zu erkennenden Zustände reduziert. Das am meisten verwendete Verfahren berücksichtigt dabei nur die zeitlichen Veränderungen in der Summenkurve zwischen zwei Messzeitpunkten. Es beruht auf der Annahme, dass die Veränderungen zwischen diesen Messzeitpunkten von maximal einem Verbraucher ausgehen. Dieses Verfahren nennt sich ereignisbasierte Deltakurve. Es reduziert die Anzahl möglicher Zustände bei den Erkennungsalgorithmen auf $N_M=N$, wieder unter der Annahme, dass jeder Verbraucher genau einen Verbraucherzustand hat.

In REALYSE verwenden wir das Verfahren der Deltakurve. Anhand von Abbildung 7 soll dies erklärt werden:




Abbildung 7: Berechnung der Deltakurve

Man nimmt bei allen 150 Messpunkten von drei aufeinanderfolgenden Messkurven (z.B. M1, M2, M3) jeweils den Median. Daraus ergibt sich eine Mediankurve, auch Fenster genannt (F_1). Die Deltakurve erhält man durch Subtraktion zweier Fenster, welche in einem Abstand von vier Messkurven voneinander liegen ($\Delta_{1,5} = F_5 - F_1$).

Gibt es kein Ereignis zwischen zwei Fenstern, besteht die Deltakurve lediglich aus Rauschen ($\Delta_{1,5}$, $\Delta_{6,10}$). Gibt es nun einen Zustandswechsel, wird in den Deltakurven, welche jeweils aus einem Fenster vor und einem Fenster nach diesem Ereignis errechnet werden, nur dieser Zustandswechsel abgebildet ($\Delta_{2,6}$, $\Delta_{3,7}$, $\Delta_{4,8}$, $\Delta_{5,9}$).

Ist der Zustandswechsel zum Beispiel das Einschalten eines neuen Verbrauchers, entspricht die Deltakurve der Stromkurve dieses neuen Verbrauchers. Wird ein Verbraucher ausgeschaltet, entspricht die Deltakurve dem nun wegfallenden Stromfluss.

Die Deltakurven bestehen wie die Rohdaten aus 150 24-Bit Werten. Diese werden an den nächsten Prozess weitergeleitet.

5.5 Merkmalsgewinnung

Die Merkmalsgewinnung haben wir, wie bereits erwähnt, nur im ersten Ansatz verwendet. Sie beschreibt die Reduktion der vielen Daten der Deltakurven auf diejenigen Parameter, welche für die nachfolgende Lasterkennung am relevantesten sind. Diese Parameter werden Merkmale genannt.

Der Vorteil dieser Einschränkung liegt in der Reduktion von Rauschkomponenten welche durch stark veränderliche, nicht relevante Parameter hervorgerufen werden. Weiter führt die Merkmalsgewinnung zu einer erheblichen Datenreduktion, was den Verarbeitungsaufwand und die Speicheranforderungen der nachfolgenden Stufen reduziert. Je kleiner die Datenmenge, desto einfacher können die Daten gespeichert, verarbeitet und gesendet werden.

Da bei REALYSE ursprünglich geplant war, alle Prozesse bis zur Merkmalsgewinnung auf dem Messsystem durchzuführen, um die Daten dann per Funktechnologie an das Analysesystem zu senden, wurden die Deltakurven auf acht Merkmale reduziert.

Im aktuellen Ansatz besteht jedoch kein Bedarf an einer Reduktion der Datenmenge, da genügend Kommunikationsbandbreite zur Verfügung steht. Deshalb wird auf den Schritt der Merkmalsgewinnung verzichtet und die Deltakurven unverändert an den nächsten Prozess weitergeleitet.

Im ersten Ansatz hingegen wurden folgende Merkmale verwendet:

- Wirkleistung (P)
- Blindleistung (Q)
- Signalanteil der ungeraden Harmonischen zur Netzfrequenz bis zur Elften (50Hz, 150Hz, 250Hz, 350Hz, 450Hz, 550Hz).

Weshalb die Wahl auf diese Merkmale fiel, wird folgend erklärt.

5.5.1 Wahl der Merkmale

5.5.1.1 Untersuchte Parameter

Um geeignete Merkmale zu finden, wurden zuerst verschiedene relevante Parameter definiert und anschließend verschiedene Kombinationen dieser Parameter mittels verschiedener Algorithmen untersucht. In Tabelle 4 werden die untersuchten Parameter zusammengefasst.

Tabelle 4: Auflistung der untersuchten Parameter

Bezeichnung	Abkürzung	Berechnungsformel	Beschreibung
Average Current	AC	$AC = \frac{1}{N} \cdot \left(\sum_{n=1}^N i(n) \right)$	Beschreibt den durchschnittlichen absoluten Stromfluss.
DC Offset	DCO	$DCO = \frac{1}{N} \cdot \left(\sum_{n=1}^N i(n) \right)$	Beschreibt die mittlere Gleichstromkomponente.
Wirkleistung	P	$P = \sum_{n=0}^{\infty} U_n \cdot I_n \cdot \cos(\varphi_n)$	Beschreibt die Wirkleistung des Verbrauchers.
Blindleistung	Q	$Q = \sum_{n=0}^{\infty} U_n \cdot I_n \cdot \sin(\varphi_n)$	Beschreibt die zusätzliche Energie pro Zeiteinheit, welche vom Energieversorger bereitgestellt wird, jedoch nicht zur Wirkleistung beiträgt.
Root Mean Square	RMS	$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N i(n) ^2}$	Beschreibt den Effektivwert des Stromes.
Fourier-Koeffizienten	FFT_CW_k	$FFT(k) = \sum_{n=1}^N i(n) \cdot e^{-j2\pi n \frac{k}{N}}$	k-ter Koeffizient der Fourier-Transformierten des Stromsignals.
Fourier-Koeffizienten	FFT_IAW_k	$FFT(k) = \sum_{n=1}^N \frac{i(n)}{u(n)} \cdot e^{-j2\pi n \frac{k}{N}}$	k-ter Fourier-Koeffizient des momentanen Leitwerts.
Fourier-koeffizienten	FFT_IPW_k	$FFT(k) = \sum_{n=1}^N i(n) \cdot u(n) \cdot e^{-j2\pi n \frac{k}{N}}$	k-ter Fourier-Koeffizient der momentanen Leistung.

Wavelet-Koeffizienten	Wlet_CW_s	$WLET(s, \tau) = \frac{1}{\sqrt{s}} \cdot \sum_{n=1}^N i(n) \cdot \Psi(n) \cdot \left(\frac{t-\tau}{s}\right)$	Wavelet-Koeffizienten aus dem Level s. Als Analyse-Wavelets wurden sym2/db2 und db10 verwendet.
Wavelet-Koeffizienten	Wlet_IAW_s	$WLET(s, \tau) = \frac{1}{\sqrt{s}} \cdot \sum_{n=1}^N i(n) \frac{i(n)}{u(n)} \cdot \Psi(n) \cdot \left(\frac{t-\tau}{s}\right)$	Wavelet-Koeffizienten aus Level s des momentanen Leitwertes.
Wavelet-Koeffizienten	Wlet_IPW_s	$WLET(s, \tau) = \frac{1}{\sqrt{s}} \cdot \sum_{n=1}^N i(n) \cdot u(n) \cdot \Psi(n) \cdot \left(\frac{t-\tau}{s}\right)$	Wavelet-Koeffizienten aus Level s der momentanen Leistung.

5.5.1.2 Selektion der Parameter

Das Tool WEKA bietet unter anderem mehrere Algorithmen zum Suchen nach geeigneten Merkmalen. In dieser Auswertung wurde der Algorithmus „InfoGainAttributEval“ verwendet. Dieser Algorithmus bewertet jeden Parameter anhand seines Informationsgewinns (Kullback-Leibler-Divergenz). Dieser bezeichnet ein Mass für die Unterschiedlichkeit verschiedener Wahrscheinlichkeitsverteilungen. In Tabelle 5 werden die Ergebnisse aus WEKA zusammengefasst. Insgesamt wurden 62 Parameter untersucht. Aufgeführt sind lediglich die besten 16.

Tabelle 5: Attribut Selektion unter Information Gain Betrachtung

Merkmal	Information Gain	Rang
AC	1.65	5
RMS	1.73	2
P	1.60	7
Q	1.88	1
FFT_CW_Abs1	1.69	4
FFT_CW_Abs3	1.36	12
FFT_CW_Abs5	1.37	11
FFT_CW_Abs7	1.18	14
FFT_CW_Abs9	0.98	16
FFT_CW_Abs11	1.16	15
Wlet_CW_0	1.58	8
Wlet_CW_1	1.64	6
Wlet_CW_2	1.32	13
Wlet_CW_3	1.53	10
Wlet_CW_4	1.57	9
Wlet_CW_5	1.72	3

Aus der Tabelle 5 geht hervor, dass von den insgesamt 62 untersuchten Parametern P, Q, AC und RMS zu den besten sieben Parametern gehören. Weiter wurden alle Wavelets, sowie alle ungeraden Harmonischen als hervorragende Merkmale identifiziert.

5.5.1.3 Beurteilung der Berechnungsdauer

Ein Kriterium für die Wahl der Merkmale ist die Berechnungsdauer auf einem Mikrocontroller. Ein Vergleich der durchschnittliche Dauer für die Berechnung der in Tabelle 4 aufgelisteten Parameter ist in Abbildung 8 dargestellt.




Abbildung 8: Durchschnittliche Dauer für die Berechnung der Parameter

Für diesen Vergleich wurden Stromkurven verwendet, welche mit einer Abtastrate von 5kHz gewonnen wurden. Sie bestehen also aus je 100 Samples. Gemessen wurde mit einer Strommesszange, angeschlossen an ein digitales Oszilloskop. Als Berechnungsgrundlage wurde ein Intel Core i7-3720QM Prozessor verwendet. Zu sehen ist, dass die Berechnung der Wavelets mit Abstand am meisten CPU Ressourcen benötigt (W_CW, W_IAW, W_IPW).

5.5.1.4 Entscheidung

Wie Abbildung 8 zeigt liegt der grosse Nachteil bei der Verwendung von Wavelets in dem relativ hohen Berechnungsaufwand. Im Vergleich zur Fourier-Transformation benötigt die Berechnung von Wavelets knapp zehnmal mehr Zeit.

Aus diesem Grund haben wir entschieden, die Fourier-Transformation mit ihrer wesentlich geringeren Performance, jedoch mit viel geringerem Berechnungsaufwand als Merkmale zu verwenden. Die Fourier-Koeffizienten bei niedrigen Frequenzen schneiden besser ab als die bei höheren Frequenzen. Bis zur elften Harmonischen werden noch gute Resultate erzielt. Dabei treten vor allem die ungeraden Harmonischen hervor.

RMS gehört ebenfalls zu den Merkmalen, die bei unterschiedlicher Klassifizierung gute Resultate liefern. Da die Berechnung des RMS Wertes das Kompositionskriterium nicht erfüllt und man davon ausgehen kann, dass bei steigendem Rauschanteil der Wert stärker vom wirklichen Wert abweicht als andere Merkmale, haben wir auch auf diesen Parameter als Bestandteil des Merkmalsektors verzichtet.

Wie bereits erwähnt, besteht der im ersten Ansatz für die Geräteerkennung verwendete Merkmalsvektor aus den Parametern P, Q und allen ungeraden Harmonischen bis zur Elften aus der Fourier-Transformation. Zur Optimierung der Erkennung haben wir sogar die ungeraden Harmonischen bis zu 71. verwendet (siehe Tabelle 7).

5.6 Geräteerkennung

Um Geräte anhand ihres Stromverbrauchs zu identifizieren werden die Deltakurven aufbereitet, diese anschliessend von einem Erkennungsalgorithmus analysiert und danach die Ergebnisse des Algorithmus statistisch verarbeitet. Zur Erreichung einer optimalen Erkennungsrate haben wir verschiedene Strategien für alle drei Teilschritte getestet. Diese werden in diesem Abschnitt detailliert erklärt. Alle Untersuchungen haben wir mit ein und demselben Datensatz getestet.

Um die Geräteerkennung zu entwickeln, haben wir einen für den späteren Einsatz repräsentativen Datensatz zum Testen erstellt. Das finale System soll im Privathaushalt eingesetzt werden und somit Geräte wie beispielsweise Lampen, Haushaltsgeräte, Ventilatoren usw. erkennen. Der Datensatz enthält eine Auswahl solcher im Haus befindlichen Geräte (siehe Tabelle 6) und bildet somit eine reelle Grundlage für die Erforschung der Erkennungsalgorithmen. Neben Testdaten benötigt ein Algorithmus Trainingsdaten für die initiale Konfiguration. Für Trainingsdaten werden Geräte individuell angeschlossen und ihre Stromkurven, in Isolation von anderen Geräten, aufgenommen. Für Testdaten werden mehrere Geräte gleichzeitig gemessen, wie es beim realen Einsatz des Systems sein wird: das Messsystem zeichnet den Gesamtverbrauch aller angeschlossen Geräte, die zufällig an und ausgeschaltet werden, auf.

Tabelle 6: Der Datensatz zur Entwicklung von NIALM.

Gerät	Gerätekategorie	Anzahl
LCD Monitor	Elektronik mit PFC	49
Ventilator	Induktive Verbraucher	47
Nespresso-Maschine	Kaffee	10
Halogen-Glühlampe	Konventionelle Beleuchtung	50
CFL-Lampe	Sparlampen	48
LED-Lampe	Sparlampen	50

5.6.1 Aufbereitung der Strommessdaten

Das Ziel der Aufbereitung der Eingangsdaten ist, auf diejenigen Merkmale der Messung zu filtern, welche die verschiedenen Verbraucher eindeutig identifizieren (siehe „5.5. Merkmalsgewinnung“). Welche Merkmale zur Unterscheidung am besten sind, hängt von den zu erkennenden Geräten ab. Die hier verwendeten Merkmale wurden für die Erkennung der in diesen Test verwendeten Geräte bestimmt und müssen für die Erkennung anderer Geräte nicht zwingend ideal sein.

Die Geräteerkennung erhält vom vorhergehenden Prozess jede Sekunde 150 Werte (Deltakurve) oder den daraus gewonnenen Merkmalsvektor. Die Geräteerkennung haben wir sowohl mit der Deltakurve als Input, als auch mit dem Merkmalsvektor getestet. Zudem haben wir mit mehreren Merkmalskombinationen und Repräsentationen getestet.

Während die Deltakurve alle möglichen Informationen unverändert beinhaltet, bilden die Merkmalskombinationen Teilmengen der möglichen Informationen. Ziel war zu bestimmen, wie viele Informationen und in welcher Form die besten Erkennungsergebnisse liefern.

Tabelle 7 zeigt die Zusammensetzung der Merkmalsvektoren, welche wir für die Tests verwendet haben. Die Harmonischen haben wir dabei sowohl in absoluter Form (dargestellt als *eine* reelle Zahl pro Harmonische), als auch in komplexer Form (dargestellt als *zwei* Zahlen: der reelle und imaginäre Teil der Harmonischen) verwendet.

Tabelle 7: Die Datensatzkonfigurationen basierend auf Merkmalen.

Bezeichnung	Merkmalskombination
SimAbsFeatures	P, Q, ungeraden Harmonischen bis zur Elften in absoluter Form
SimComFeatures	P, Q, ungeraden Harmonischen bis zur Elften in komplexer Form
ExtAbsFeatures	P, Q, ungeraden Harmonischen bis zur 71. in absoluter Form
ExtComFeatures	P, Q, ungeraden Harmonischen bis zur 71. in komplexer Form

In der Originalverteilung hat die Deltakurve einen Wertebereich von -25 A bis 25 A, das Merkmal P von 0 bis 4065 W, Q von -4065 VA bis 4065 VA und die Harmonischen von -25 A bis 25 A. Neben der Deltakurve und dem Merkmalsvektor in unveränderter Form, haben wir für die Tests die Werte in neue

Wertebereiche konvertiert:

- In den Wertebereich von 0 bis 1 (normalisiert).
- In den logarithmischen Wertebereich, um Ausreisser zu kompensieren
- In den positiven Wertebereich, da manche Erkennungsalgorithmen nur mit positiven Zahlen arbeiten.

5.6.2 Erkennungsalgorithmus

Die eingehenden Daten werden analysiert um einen Event zu detektieren, den erkannten Event einer Gerätekategorie zuzuordnen und danach das spezifische Gerät zu erkennen.

Die Erkennung läuft in mehreren Stufen. Das bedeutet, dass nur, wenn ein Event erkannt wird, versucht wird, die dafür verantwortliche Gerätekategorie zu bestimmen und das spezifische Gerät zu identifizieren. Die Erkennung eines Events – das ist der Ein-oder Ausschaltvorgang eines Geräts – und die Zuordnung zu einer Gerätekategorie passieren in einem Schritt. Abhängig vom verwendeten Algorithmus geschieht dies mit einer von zwei Strategien. Bei der ersten Strategie wird zusätzlich zu den vorhandenen Gerätekategorien eine weitere Kategorie „Rauschen“ eingeführt. Diese Kategorie repräsentiert das nichts passiert. Wenn also die Kategorie Rauschen erkannt wird, ist kein Event geschehen. Die zweite Strategie bedingt, dass der Algorithmus für die erkannte Gerätekategorie einen Wahrscheinlichkeitsfaktor errechnet. Nur wenn dieser Faktor über einem vordefinierten Wert liegt, hat das assoziierte Gerät seinen Zustand geändert und damit ein Event ausgelöst. Tabelle 9 detailliert die Fähigkeiten der getesteten Algorithmen.

Die Anzahl der verschiedenen zu erkennenden Geräte beeinflusst die Komplexität der Erkennung. Je weniger verschiedene Geräte erkannt werden sollen, desto bessere Ergebnisse liefert der Algorithmus. Es ist leichter eins aus zwei möglichen Geräten zu erkennen als eines aus 50.

Um eine gute Genauigkeit zu garantieren, passiert die Erkennung in zwei Stufen. In der ersten Stufe wird eine von neun vordefinierten Gerätekategorien (siehe Tabelle 8) erkannt und so eine geringe Anzahl von Erkennungskandidaten garantiert. In der zweiten Stufe wird das spezifische Gerät erkannt. Für jede Stufe existiert ein separater und spezialisierter Erkennungsalgorithmus. Für dieses Projekt wird derselbe Algorithmus für beide Stufen benutzt. Allerdings werden die beiden Algorithmen unterschiedlich trainiert und somit auf die jeweilige Stufe spezialisiert.

Tabelle 8: In REALYSE vordefinierte Gerätekategorien.

Gerätekategorie	Beschreibung	Beispiele
Elektronik ohne PFC	Schaltnetzteil unter 75W ohne Power Factor Correction	Laptop, Tintenstrahldrucker
Elektronik mit PFC	Schaltnetzteile mit Power Factor Correction	Monitor, TV, PC, Laserdrucker
Konventionelle Beleuchtung	Alle Glühlampen	Glühlampen, Halogenlampen
Sparlampen	Lampen mit Vorschaltgerät	CFL-Lampen, LED-Lampen, FL-Röhren
Kaffee	Kaffeemaschinen	Nespresso-Maschine, Kaffeefullautomat
Induktive Verbraucher	Geräte mit Elektromotor als Hauptlast	Bohrmaschine, Mixer, Ventilator
Low Power	Kleinstgeräte mit Schaltnetzteil	Smartphone-Ladegeräte,
Ohm'sche Verbraucher	Ohm'sche Verbraucher mit grosser Last	Wasserkocher, Kochherd, Elektroheizungen, Elektroboiler
Kühlgeräte	Geräte mit Kühlkompressor	Kühlschrank, Gefriertruhe

Der Grundgedanke der zwei Stufen ist, dass der Nutzer nicht an jedem einzelnen Gerät und dessen spezifischen Verbrauch interessiert ist, sondern lediglich an einigen ausgewählten Geräten. Durch die Aufteilung in zwei Stufen wird die Erkennung vereinfacht, indem Geräte von keinem speziellen Interesse zu Klassen zusammengefasst werden und nur eine Teilmenge aller Geräte wirklich individuell erkannt werden muss. Wenn der Nutzer beispielsweise eine neue LED-Lampe kauft, ist er an dieser interessiert, nicht aber an allen anderen Lampen. Schaltet er eine der anderen Lampen an, wird die Gerätekategorie „Sparlampe“ erkannt und der dazugehörige Verbrauch angezeigt, nicht aber welche Lampe es nun genau ist. Nur wenn die neu erstellte LED-Lampe eingeschaltet wird, wird neben der Gerätekategorie „Sparlampe“ auch erkannt und angezeigt, dass es eben diese LED-Lampe ist.

Ein weiterer Vorteil der Strategie der zwei Erkennungsstufen ist, dass neu hinzugefügte Geräte ohne

neues Training in der ersten Stufe erkannt werden. Da Geräte einer Klasse ähnliche Verbrauchereigenschaften aufweisen, wird der Algorithmus auf diese klassenspezifischen Eigenschaften trainiert und kann damit Geräte der Klasse zuordnen die er noch nie gesehen hat.

Bei der Erkennung der Geräteklassen wurde ein Mehrheits-Voting Verfahren verwendet. Idealerweise wird ein Event in vier aufeinanderfolgenden Events reflektiert (siehe Abschnitt „5.4 Datenvorbereitung“): der Algorithmus sollte also das gleiche Ergebnis für vier aufeinanderfolgende Erkennungen liefern. Darauf basierend wurde ein Mehrheits-Voting mit mehreren Regeln implementiert.

1. Wenn die Erkennung drei Mal hintereinander das gleiche Ergebnis liefert, wird es als korrekt akzeptiert.
2. Wenn der Algorithmus innerhalb von vier aufeinanderfolgenden Erkennungen drei Mal das gleiche Ergebnis liefert, wird es als korrekt akzeptiert.
3. Wenn der Algorithmus zusätzlich eine Wahrscheinlichkeit berechnet und diese für eine individuelle Erkennung über 95% ist, wird es sofort akzeptiert.
4. Wenn der Algorithmus zusätzlich eine Wahrscheinlichkeit berechnet und diese nicht einen Mindestwert von 60% überschreitet, wird die individuelle Erkennung als falsch akzeptiert. Selbst wenn vier aufeinanderfolgende Erkennungen die gleiche Gerätekategorie als Ergebnisse liefern, wird es nicht akzeptiert, wenn nicht mindestens drei eine Wahrscheinlichkeit über 60% haben.

Um den besten Algorithmus zu bestimmen wurden mehrere Algorithmen mit verschiedenem Input getestet (siehe Abschnitt „5.6.2.1 Evaluation der Algorithmen“). Das WEKA Framework implementiert eine Vielzahl von Algorithmen und kann direkt in einer Software als Bibliothek eingebunden werden. Tabelle 9 listet die getesteten Algorithmen. Zusätzlich zu den in WEKA implementierten Algorithmen wurden zwei weitere Algorithmen getestet: Die „Support Vector Machine“ aus der LibSVM-Bibliothek, und der Template Matcher.

Tabelle 9: Die getesteten Algorithmen, ihre Fähigkeiten und Herkunft.

Algorithmus	Fähigkeiten			Quelle
	Wahrscheinlichkeit	Neu trainieren	Erkennungsgeschwindigkeit	
BFTree	Nein	Ja	Sehr schnell	WEKA
Support Vector Machine	Ja	Ja	Schnell	LibSVM
Multi Layer Perceptron	Ja	Ja	Schnell	WEKA
Bayes Network	Ja	Ja	Schnell	WEKA
Decorate	Ja	Ja	Schnell	WEKA
Template Matcher	Ja	Nein	Mittel	Eigene Implementation

5.6.2.1 Evaluation der Algorithmen

5.6.2.1.1 Anforderungen

Im Laufe der Untersuchungen kristallisierten sich mehrere Anforderungen an den Algorithmus heraus. So wird erstens eine Erkennung mit assoziierter Wahrscheinlichkeit gefordert. Diese Wahrscheinlichkeit drückt die Qualität der Erkennung aus und erlaubt uns, eine Erkennung zu ignorieren, falls die Wahrscheinlichkeit zu gering ist. Zweitens sollte kein erneutes Training nötig sein, wenn ein neues Gerät erkannt werden soll. Und drittens ist eine schnelle Erkennung gefordert.

Neben diesen Anforderungen wird vom Algorithmus eine sehr hohe Genauigkeit der Erkennung gefordert. Jedoch gibt es verschiedene Arten der Genauigkeit. Hier werden diese beschrieben und priorisiert.

Genauigkeit der Eventerkennung

Im Idealfall werden 100% aller auftretenden Events erkannt (richtig positiv). Gleichzeitig dürfen keine Events erkannt werden, wo auch keine Events sind (richtig negativ). In der Realität kann es aber vorkommen, dass auftretende Events nicht erkannt werden (falsch negativ) oder dass Events erkannt werden, wo keine Events sind (falsch positiv).

Als höchste Priorität wird hier der Anteil der richtig positiven Ergebnisse genommen (Zielwert: 100%), jedoch unter der Bedingung, dass die Zahl der falsch positiven Erkennungen 2% der Gesamtzahl der Events nicht übersteigt.

Genauigkeit der Klassifizierung

Im Idealfall wird bei allen erkannten Events dem verursachenden Gerät die richtige Geräteklasse zugeordnet. Realistisch gesehen kann es aber sein, dass es hier falsche Zuordnungen gibt.

Nach der korrekten Eventerkennung hat die genaue Klassifizierung der Geräte zweithöchste Priorität.

Genauigkeit der Geräteerkennung

Nur wenn ein Event erkannt wurde und dem Verursacher eine Geräteklasse zugeordnet wird, wird die Geräteerkennung auf der zweiten Stufe aktiviert. Hier wird erwartet, dass die trainierten Geräte zu 100% richtig erkannt werden. Unter den Genauigkeiten hat die der Geräteerkennung die niedrigste Priorität.

5.6.2.1.2 Identifikation der Algorithmen

Im Folgenden werden die Schritte zur Identifikation des besten Algorithmus bündig aufgezeigt.

1. Wir identifizierten Typen von Algorithmen die mindestens zwei von drei Anforderungen erfüllen. Daraus resultieren:
 - a. Bäume
 - b. Classification Rules
 - c. Naïve Bayesian
 - d. Linear Classifiers
 - e. Lazy Learners
2. Um innerhalb der Algorithmientypen, einzelne Kandidaten zu identifizieren, wurden alle verfügbaren Algorithmen der verschiedenen Typen mit den Trainingsdaten trainiert und getestet. Der Vorteil der Trainingsdaten ist, dass sie schnell und von vielen Geräten aufgezeichnet werden können. Der Nachteil ist, dass sie nicht der Realität entsprechen da sie nur das Verhalten eines Gerätes in Isolation beschreiben.
3. Für jeden gewählten Algorithmus wurden verschiedene Parametereinstellungen zur Optimierung auf den Trainingsdaten getestet, um die Kandidatenliste weiter zu trimmen.
4. Die identifizierte Kandidatenliste wurde weiter gekürzt mit dem realen Datensatz. Die resultierenden Kandidaten sind in Tabelle 9 beschrieben.
5. Für jeden der verbleibenden Algorithmen wurden verschiedene Parametereinstellungen zur Optimierung auf den realen Testdaten getestet, um die optimalen Einstellungen herauszufinden.
6. Die Ergebnisse aller verbleibenden Algorithmen auf dem realen Testdatensatz wurden analysiert und untereinander verglichen.

5.6.2.2 Beste Algorithmen

Folgend werden die beiden erfolgversprechendsten Algorithmen genauer erklärt.

5.6.2.2.1 BFTree

Der BFTree ist ein Algorithmus der das Erlernte als binären Baum darstellt und dadurch eine sehr schnelle Erkennung erlaubt. Beim Trainieren analysiert der BFTree die Trainingsdaten und bestimmt die Attribute inklusive der dazugehörigen Grenzwerte, die die zu erkennenden Geräte am besten unterscheiden. Wenn ein neues Gerät zu den zu erkennenden Geräten hinzugefügt werden soll, muss der Algorithmus neu trainiert werden.

Wenn ein trainierter BFTree einen Dateneintrag bekommt und diesem ein Gerät zuordnen soll, wird zuerst die Bedingung im obersten Knoten getestet (Abbildung 9). Je nach Ergebnis wird als nächstes die Bedingung im linken oder rechten Kind des Knotens getestet. Knoten ohne Kinder beinhalten anstatt einer Bedingung ein zugeordnetes Gerät. Wenn also ein Knoten ohne Kinder erreicht wird, ist die Bestimmung beendet und das Ergebnis der Erkennung ist das in diesem Endknoten angegebene Gerät.

Der BFTree retourniert immer ein Ergebnis aber assoziiert keine Wahrscheinlichkeit. Aus diesem Grund enthält der Datensatz immer das zusätzliche Gerät „Rauschen“, um feststellen zu können, dass nichts passiert ist. Dieses Rauschen wird wie alle anderen Geräte isoliert trainiert, es beschreibt also das Rauschen des Messsystems selber. Wenn im realen Einsatz mehrere Geräte laufen ohne ihren Zustand zu ändern, dann ist das dortige Rauschen die Summe des Rauschens aller Geräte und dem trainierten Rauschen nicht mehr ähnlich. Eine Lösung wäre alle Rauschkombinationen zu trainieren. So müsste das Rauschen bei allen möglichen Gerätekombinationen aufgezeichnet und trainiert werden. Dies würde aber in einem exponentiellen Mehraufwand resultieren.

Abbildung 9 zeigt einen trainierten BFTree. Wenn ein neuer Testsatz kommt, wird zuerst die Bedingung im obersten Knoten getestet. Wenn ein Knoten keine Kinder mehr hat ist man am Ende und damit an dem zu bestimmenden Gerät angekommen.




Abbildung 9: Ein trainierter BFTree.

5.6.2.2.2 Template Matcher

Der Template Matcher benutzt eine Bibliothek von Templates, mit denen ein unbekanntes Template, der Kandidat, verglichen wird. Ein Template beschreibt die gemessenen Daten von einem Gerät. Beim verwendeten Messsystem sind das entweder die 150 Werte aus der Deltakurve oder der Merkmalsvektor. Für jedes Gerät gibt es mehrere Templates in der Bibliothek. Wieviel Templates benötigt werden, hängt vom Verbrauchsverhalten des Geräts ab: verbraucht ein Gerät konstant gleich viel Strom, ohne grosse Fluktuationen, genügen wenige Templates (10 oder weniger). Die Templates aller zu erkennenden Geräte formen die Bibliothek. Im Gegensatz zum BFTree trainiert der Template Matcher nicht. Bei der Erkennung eines Kandidaten wird besagter Kandidat mit allen Templates aus der Bibliothek verglichen und das dem Kandidaten ähnlichste Template bestimmt die Klasse: der Kandidat wird dem Gerät zugeordnet, welchem auch das Template zugeordnet ist.

Die Ähnlichkeit zwischen Kandidaten und Template wird durch eine Distanzfunktion berechnet. Um die Distanz zu berechnen werden alle Werte des Kandidaten (K) vom dazugehörigen Wert des Templates (T) abgezogen und die Differenzen aufaddiert (Formel 2). Bei einem genauen Match sollte jede Subtraktion 0 ergeben und damit die Distanz 0 sein.

$$dist = \sum_{i=1}^N K[i] - T[i]$$

Formel 2

Wenn die Distanzen vom Kandidaten zu allen Templates berechnet wurden, wird das Template mit der geringsten Distanz genommen. Dieses Template hat ein zugeordnetes Gerät das nun auch zum Kandidaten zugeordnet wird: wurde das Template von einem Staubsauger erzeugt, so muss auch der unbekannte Kandidat von einem Staubsauger kommen. Vergleicht man diese berechnete kürzeste Distanz mit der maximal möglichen Distanz zwischen Kandidaten und Template, kann man eine Übereinstimmung und damit eine Wahrscheinlichkeit berechnen.

Der Template Matcher benötigt kein initiales Training wie beispielsweise der BFTree. Bei jeder Erkennung benutzt der Template Matcher die unveränderten Messdaten (Templates) aller zu erkennenden Geräte. Durch diese Strategie entfällt das Training sowohl beim initialen Setup, als auch beim Hinzufügen oder Entfernen von Geräten. Der Nachteil ist der Rechenaufwand und die damit benötigte Zeit pro Erkennung, denn jedes Mal müssen alle Templates angeschaut werden. Zudem brauchen alle Templates mehr Speicher als die meisten Modelle die beim Training von anderen Erkennungsalgorithmen erstellt werden.

5.6.3 Ergebnisse der Geräteerkennung

Nachdem der Template Matcher als bester Algorithmus identifiziert wurde, optimierten wir diesen für die verschiedenen Formen des Inputs: Erkennung basierend auf den reinen Deltakurven, den Merkmalen mit sechs und 36 ungeraden Harmonischen inklusive der verschiedenen Darstellungen dieser (siehe reelle und komplexe Form in Abschnitt „5.6.1 Aufbereitung der Strommessdaten“). Zusätzlich wurden sowohl verschiedene Verformungen der Eingangsdaten, als auch eine Optimierung der Distanzfunktion getestet.

Im Folgenden sind die Ergebnisse der Tests zusammenfassend erklärt. Die genauen Resultate sind in Tabelle 11 und Tabelle 12 abgebildet.

Der Template Matcher erkennt sowohl die Geräteklassen, als auch Geräte am zuverlässigsten. Vor

allein bei der Erkennung der Events und der damit verbundenen Geräteklassen sticht der Template Matcher die anderen Algorithmen aus. Einer der Hauptgründe ist seine Robustheit gegen Störungen. Wenn mehrere Geräte gleichzeitig laufen und eines (z.B. die LED-Lampe) den Zustand ändert, dann wird die Messungen dieser Änderung zur Erkennung benutzt. Das Problem ist, dass diese Messung nicht nur die durch die LED-Lampe verursachte Änderungen abbildet, sondern auch die Schwankungen aller anderen Geräte an diesem Messknoten. Diese Schwankungen mögen klein sein, aber aufaddiert können sie eine 6W LED-Lampe wie ein 12W Ventilator aussehen lassen. Der Template Matcher erkennt in diesem Fall ein falsches Gerät aber mit einer geringen Wahrscheinlichkeit, sodass die zu analysierenden Messungen nicht einem falschen Gerät zugeschrieben werden.

Eine weitere Stärke des Template Matchers ist das Erkennen von Geräten mit geringem Verbrauch. Wegen der vorher beschriebenen Schwankungen ist es besonders schwierig, Geräte mit einem niedrigen Verbrauch zu erkennen. Solche geringen Verbraucher werden meist über die hohe Wahrscheinlichkeit einer der vier aufeinanderfolgenden Messungen identifiziert. Dies ist nur möglich, weil der Template Matcher auch eine Wahrscheinlichkeit für jede Erkennung berechnet. Zudem haben geringe Verbraucher meist ein sehr typisches Verbraucherverhalten was besonders gut unter Verwendung der Deltakurven erkannt wird.

Gute Ergebnisse liefert auch der BFTree, kommt aber nicht an den Template Matcher heran (Tabelle 10).

Tabelle 10: Der Template Matcher und der BFTree getestet mit dem Rohdatensatz

	Template Matcher	WEKA / BFTree
Stage 1		
# Events	254	254
# Erkannte Events	256	256
# Korrekt erkannte Events	252	250
# Korrekt klassifizierte Geräte	252	248
Stage 2		
# Korrekt erkannte Geräte	252	209

Das beste Ergebnis erzielt der Template Matcher mit den unveränderten 150 Werten der Deltakurve. Wie in Tabelle 11 ersichtlich, erkennt der Algorithmus 252 von tatsächlichen 254 Events und vier Events die gar keine sind. Das ignorieren von falschen Events, das sind Stromschwankungen, die ohne Zustandsänderung eines Geräts gemessen werden, ist eine grosse Herausforderung. Wenn der Algorithmus zu sensitiv konfiguriert ist, kann in jeder Messung ein Event erkannt werden (z.B. Support Vector Machine, Tabelle 11).

Von den erkannten 252 Events werden vom Template Matcher alle der richtigen Gerätekategorie zugeordnet. In der zweiten Stufe werden auch alle Events dem richtigen Gerät zugeordnet.

In Tabelle 11 sind die Testergebnisse einer Auswahl der getesteten Algorithmen mit den verschiedenen Datensätzen aus Tabelle 6 zu finden. Die erste Zahl gibt dabei die korrekte Anzahl an, die zweite Zahl die Gesamtzahl. 250/254 bedeutet zum Beispiel das der Algorithmus 250 von 254 richtig hat. Alle Algorithmen aus externen Quellen wurden mit den merkmalsbasierten Datensätzen getestet.

Tabelle 11: Testergebnisse einer Auswahl der getesteten Algorithmen.

Algorithmus und Konfiguration	Richtig erkannte Events	Insgesamt erkannte Events	Richtig erkannte Gerätekategorie	Richtig erkannte Geräte
Template Matcher mit Deltakurve (150 Werte)	252/254	256/254	252/252	252/252
Algorithmen aus externen Quellen (WEKA, LibSVM)				
Support Vector Machine mit normalisierten Werten	254/254	1996/254	21/254	15/254
Multi Layer Perceptron mit komplexem Merkmalsvektor	126/254	963/254	27/126	18/126
Bayes Network	43/254	75/254	43/43	40/43
Decorate	130/254	249/254	14/130	18/130
BFTree	250/254	256/254	248/250	209/250

Die Nachteile am Benutzen aller 150 Werte sind das Datenvolumen und die Erkennungsgeschwindigkeit. Das Speichern aller Templates in der Bibliothek benötigt mehr Platz, wenn jedes Mal 150 Werte gespeichert werden. Das ist deutlich mehr als die acht Werte pro Template, wie dies bei den Merkmalsvektoren der Fall ist (der genaue Bedarf hängt von der Konfiguration der Merkmale ab). Auch bei der Erkennung spielt die Grösse des Inputs eine Rolle: die Distanzberechnung eines jeden Templates zum Kandidaten (siehe Abschnitt „5.6.2.2.2 Template Matcher“) berücksichtigt alle 150 Werte innerhalb eines Templates.

Um den Nachteil der grossen Templates zu adressieren, haben wir versucht, die Merkmale zu optimieren. Die Vermutung ist, dass die reinen Deltakurven Informationen enthalten die bei der Extrahierung der Merkmale verloren gehen. Diesen Verlust galt es zu kompensieren indem mehr Merkmale verwendet wurden und zum Teil deren Darstellung verändert wurde. Die Ergebnisse sind in Tabelle 12 abgebildet.

Tabelle 12: Ergebnisse der Tests mit dem Template Matcher und verschiedenen Formen der Eingabedaten.

Eingabedaten	Richtig erkannte Events	Anzahl insgesamt erkannter Events	Anzahl der richtig erkannten Geräteklasse	Anzahl der richtig erkannten Geräte
Deltakurve (150 Werte)	252/254	256/254	252/252	252/252
6 ungerade Harmonische	252/254	258/254	251/252	240/252
6 ungerade Harmonische, normalisiert	247/254	1125/254	244/254	210/252
6 ungerade Harmonische, gewichtete Distanzfunktion	254/254	262/254	252/254	243/254
6 ungerade Harmonische, transformiert (x^2), gewichtete Distanzfunktion	249/254	253/254	247/249	235/249
6 komplexe ungerade Harmonische	127/254	132/264	126/127	120/127
6 komplexe ungerade Harmonische, normalisiert	186/254	472/254	149/186	126/186
6 komplexe ungerade Harmonische, gewichtete Distanzfunktion	125/254	128/254	123/125	117/125
6 komplexe ungerade Harmonische, Transformiert (x^2), gewichtete Distanzfunktion	131/254	136/254	127/131	125/131
36 ungerade Harmonische	229/254	235/254	194/294	149/229
36 ungerade Harmonische, gewichtete Distanzfunktion	254/254	264/254	201/254	181/254
36 ungerade Harmonische, normalisiert, gewichtete Distanzfunktion	210/254	971/254	176/210	138/229
36 komplexe ungerade Harmonische	36/254	36/254	36/36	36/36
36 komplexe ungerade Harmonische, gewichtete Distanzfunktion	112/254	114/254	110/112	85/112
36 komplexe ungerade Harmonische, normalisiert, gewichtete Distanzfunktion	137/254	138/254	136/137	131/137

Es ist erkennbar, dass die Verwendung der maximalen Anzahl der verfügbaren Harmonischen keine besseren Ergebnisse bringt. Im Gegenteil, die Ergebnisse sind signifikant schlechter. Die höheren Harmonischen sind zu unbeständig: wenn man mehrere Messungen desselben Gerätes vergleicht, stechen die Schwankungen der höheren Harmonischen heraus. Betrachtet man die höheren Harmonischen eines Gerätes während noch andere Geräte eingeschaltet sind, sind die Schwankungen noch höher. Diese Unbeständigkeit macht die höheren Harmonischen zu schlechten Merkmalen mit einem negativen Mehrwert.

Das Aufbrechen der Darstellung der Harmonischen in ihren komplexen und imaginären Teil bringt keine Verbesserung der Ergebnisse. Für den imaginären Teil der Harmonischen gilt ähnliches wie für die höheren Harmonischen: der imaginäre Teil ist sehr unbeständig und variiert für einen zuverlässigen Prädiktor zu stark.

Das beste Ergebnis erzielt die Kombination Template Matcher und Merkmalsvektor mit den ersten sechs ungeraden Harmonischen. Im Vergleich zu den 150 Messwerten, erkennt der Template Matcher mit den acht Merkmalen mehr nicht existierende Events und hat ein leichtes Defizit bei der Erkennung der Geräteklassen. Der grösste Unterschied ist bei der Erkennung der Geräte in der zweiten Stufe: im Gegensatz zum fehlerlosen „150 Werte Template Matcher“, kommt der „Merkmalsvektor Template Matcher“ nur auf 95,24%. Etwas besser ist die Geräteerkennung wenn eine gewichtete Distanzfunktion verwendet wird. Eine zusätzliche Transformierung der Vektoren verbessert zwar die Eventdetektion, verschlechtert aber die Geräteerkennung. Diese feinen Unterschiede in der Performance werden deutlicher mit grösseren Datensätzen und mehr zu erkennenden Geräten.

Die besten Ergebnisse liefert also der Template Matcher unter Verwendung der 150 Werte der Delta-kurve, weshalb diese Kombination verwendet wird.

5.7 Benchmarking

Damit der Benutzer einen grösseren Nutzen aus der Geräteerkennung und den dazu gesammelten Messwerten ziehen kann, soll er in der Lage sein, das erkannte Gerät mit nur einem Knopfdruck mit den energieeffizientesten Geräten derselben Kategorie zu vergleichen.

Um einen solchen Vergleich zu ermöglichen, müssen die besten Geräte der jeweiligen Kategorie vermessen und in einer Datenbank zusammen getragen werden. Als Dienstleister einer solchen Datenbank wurde TopTen.ch verwendet. Der Aufbau der TopTen.ch Datenbank ist sehr ähnlich derer von uns intern zur Speicherung der erkannten Geräte verwendeten Datenbank. Sie ist in Kategorien und Geräte aufgeteilt, ähnliche Entitäten werden durch die erste Erkennungsstufe unsererseits abgebildet.

Über die Identifikationsnummer einer Kategorie werden während des Betriebes, mittels einer Web-API, die Daten abgefragt. Zur Sicherstellung der Privatsphäre wird der Datenstrom mittels einer AES-128 Verschlüsselung gesichert. Die Informationen, welche zu einem Gerät zur Verfügung stehen, variieren stark in Abhängigkeit der Kategorie des Gerätes. Diese nicht konsistente Menge an Informationen pro Geräteklasse gestaltet die automatisierte Weiterverarbeitung sehr schwierig. Aufgrund dieses Umstandes wurde darauf verzichtet ein Energielabel pro Gerät zu berechnen.

Um dennoch einen brauchbaren Vergleich anstellen zu können, werden dem Benutzer die besten Geräte seiner Kategorie in einer tabellarischen Form angezeigt. Durch die detaillierten Informationen und die übersichtliche Darstellung ist es dem Benutzer möglich, einen Vergleich anhand seiner Kriterien vorzunehmen.

In Abbildung 10 ist ein Ausschnitt aus der topten.ch-Webseite zu sehen. In diesem Beispiel sind die energieeffizientesten Leuchtmittel zwischen 400lm und 750lm mit E27-Fassung gelistet. Dieselbe Liste wird im REALYSE-Demonstrator verwendet (Abbildung 11). Hier werden aber nur die wichtigsten Informationen (Effizienzklasse, Lichtstrom, Leistung und Lumen pro Watt) angezeigt. Auch ist zu sehen, dass die topten.ch-Datenbank regelmässig aktualisiert wird. So wurden die Daten, welche für die Liste in Abbildung 11 verwendet wurden im August 2015 abgefragt. Die in Abbildung 10 gezeigte Liste hingegen ist von Ende November 2015.

										
☛ vergleichen										
☛ Marke	Xnovum	Osram	Onlux	Philips	Wiva	Ledisong DHSBC	Xnovum	Xnovum	Xnovum	Le
☛ Modell	LCC Glühlampenform 6W	LED Retrofit Classic A 40 FIL	Filux A60-6C	LED Classic 4.3W CL ND/4	Wire LED Goccia Chiara	A19C - 6.5 W	LCC Glühlampenform 5.5W klar	LCC Spiegelkopflampe	LCC Glühlampenform 5.5W matt	A1
☛ Weitere Modelle						Ra 90	5500K			
☛ Kaufpreis (Fr.)	35	11	14	11	15	20	30	33	30	20
☛ Stromkosten (Fr. in 15 J.)	18	12	13	13	18	20	17	17	17	20
☛ Effizienzklasse	A++	A++	A++	A++	A++	A+	A++	A+	A+	A+
☛ Lichtstrom (lm)	750	470	504	470	630	660	550	550	550	60
☛ Leistung (Watt)	6	4	4.3	4.3	6	6.5	5.5	5.5	5.5	6.5
☛ Lumen pro Watt (lm/W)	125	118	117	109	105	102	100	100	100	92
☛ entspricht Glühlampen-Leistung (Watt)	70	40	44	40	50	55	55	55	55	51
☛ Lebensdauer (Stunden)	35'000	15'000	25'000	15'000	15'000	25'000	35'000	35'000	35'000	25
☛ Ein-Aus-Schaltungen	k.A.	100'000	100'000	20'000	20'000	100'000	k.A.	k.A.	k.A.	10
☛ Dimmbar	x	x	x	x	x	x	✓	✓	✓	x
☛ Warmweiss	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
☛ Länge (mm)	105	105	104	104	107	108	110	110	110	10
☛ Durchmesser (mm)	60		60	60	60	60	60	60	60	60

Abbildung 10: Ausschnitt aus der topten.ch-Webseite, hier am Beispiel von LED-Leuchtmitteln [5].

			
Effizienzklasse	A++	A+	A+
Lichtstrom (lm)	504	580	660
Leistung (Watt)	4.3	5.5	6.5
Lumen pro Watt (lm/W)	117	105	102

Abbildung 11: Darstellung der TopTen-Datenbank im Demonstrator.

5.8 Demonstrator

Um die Ergebnisse des Projekts REALYSE an der EEDAL 2015 einem breiten und internationalen Fachpublikum zu präsentieren, haben wir einen Demonstrator entworfen und gebaut. Dem Besucher sollte damit gezeigt werden, dass mit den Informationen, welche aus der Lastaufschlüsselung gewonnen werden können, neue Möglichkeiten bezüglich Energiesparen, Effizienzsteigerung, Komfort und Sicherheit eröffnet werden.

In Abbildung 12 ist der REALYSE-Demonstrator zu sehen. Er besteht aus den folgenden Komponenten:

1. Messsystem (in der Box)
Die vom iHomeLab für NIALM-Anwendungen entwickelte Hardware mit Mikrocontroller und Kommunikationseinheit.
2. Analysesystem (in der Box, nicht sichtbar)
Raspberry Pi 2 mit der Analysesoftware installiert.
3. Touchscreen mit Frontend
Hier werden die Ergebnisse der Lastaufschlüsselung visualisiert.
4. Steckdosen
Hier können die zu messenden Verbraucher angeschlossen werden.
5. Die zu messenden Verbraucher:
 - a. Kaffeemaschine Nespresso Pixie
 - b. Ventilator Intertronic RT-23
 - c. Monitor Samsung SyncMaster 245B
 - d. Halogenleuchtmittel Coop Qualité & Prix 28W
 - e. LED-Leuchtmittel Philips LED Dimmable 6W
 - f. CFL-Leuchtmittel Philips Tornado 8W
6. Backend-Server (nicht auf dem Bild).
Hier werden die Daten für die Visualisierung aufbereitet und die Anbindung an TopTen.ch realisiert.




Abbildung 12: REALYSE-Demonstrator

Für den Demonstrator haben wir eine Windows-Applikation entwickelt, welche auf einfachste Weise das Prinzip von REALYSE veranschaulicht.

Der Startbildschirm fordert dazu auf, ein Gerät an die Steckdose auf dem Tisch anzuschliessen (Abbildung 13).




Abbildung 13: Startbildschirm Demonstrator

Schliesst man nun ein Gerät an, wird dieses erkannt und die Geräte-Ansicht (Abbildung 14) mit dem erkannten Gerät (linke Spalte) und der Gerätekategorie zu welcher das Gerät gehört (rechte Spalte) wird angezeigt. In der linken Spalte wird zusätzlich die Leistungsaufnahme pro Gerät, in der rechten Spalte die kumulierte Leistungsaufnahme pro Gerätekategorie angezeigt. Falls zum erkannten Gerät eine TopTen.ch-Datenbank existiert, wird der TopTen-Button angezeigt (siehe auch Abbildung 15).




Abbildung 14: Geräte-Ansicht mit nur einem Gerät



Abbildung 15: Elemente der Geräte-Ansicht

Schliesst man weitere Geräte an, werden diese ebenfalls angezeigt (Abbildung 16). Ein Gerät, welches dem System nicht bekannt ist, wird folglich auch nicht in der Geräteliste angezeigt, jedoch dessen Geräteklasse inklusive der Leistungsaufnahme. Im Falle von Abbildung 16 wurde ein iPhone mit Ladegerät eingesteckt. Da iPhones dem System nicht bekannt sind, wird es lediglich als Gerät der Klasse „Low Power“ erkannt (rechte Spalte, unten).



Abbildung 16: Geräte-Ansicht mit mehreren Geräten

Klickt man bei einem Gerät in der Liste auf den TopTen-Button, öffnet sich die Ansicht in Abbildung 17. Hier werden die Geräte, welche auf dem Vergleichsportal TopTen.ch als besonders energieeffizient gelistet sind, inklusive ihrer Eigenschaften, gezeigt. Abbildung 17 zeigt dies am Beispiel des PC-Monitors.

Für einige Geräte, wie zum Beispiel den Ventilator, existiert keine Datenbank auf TopTen.ch. Daher wird dort auch kein Button angezeigt.




Abbildung 17: TopTen-Ansicht, hier am Beispiel des PC-Monitors

Beim Demonstrator ist darauf zu achten, dass die Geräte in Abständen von mindestens drei Sekunden eingesteckt werden. Dies zeigt die Problematik, dass Geräte, welche quasi gleichzeitig eingeschaltet werden nicht voneinander unterschieden werden können. Dies ist im Abschnitt „6.3.3.2 Gleichzeitige Ereignisse“ näher erläutert.

5.9 Publikationen

5.9.1 Papers

An der EEDAL 2015 haben wir mit zwei Papers Ergebnisse aus dem Projekt REALYSE präsentiert. Folgend sind die Titel und Abstracts zu diesen Papers zu finden.

Titel:

Using a Cascading Classifier to improve the Recognition Performance of NIALM

Autoren:

Marcel Mathis und Alexander Klapproth.

Abstract:

People are willing to save energy yet most have little to no understanding about the energy consumption of their household devices. Non-intrusive appliance load monitoring (NIALM) is an approach to automatically measure a household's energy consumption and identify switched-on appliances. This paper presents our ongoing research on improving electric load recognition thus helping people to better understand their energy consumption.

Depending on what current NIALM approaches identify, they have either high recognition accuracy or can recognize a lot of different devices. This approach uses a two stage cascading algorithm which recognizes groups of similar devices states in the first and individual devices states in the second stage. From a user perspective, the first classifier is an out-of-the-box algorithm with high recognition accuracy due to a low number of classes. The second classifier is trained by users with specific devices they want detailed information about. Our novel approach has an overall recognition accuracy of 87% and more. [6]

Titel:

Recognizing Appliances and their Events with the same NIALM Algorithm

Autoren:

Marcel Mathis, Patrick Huber und Alexander Klapproth.

Abstract

People are willing to save energy yet most have little to no understanding about the energy consumption of their household devices. Non-intrusive appliance load monitoring (NIALM) is an approach to automatically measure a household's energy consumption and identify switched-on appliances. This paper presents our ongoing research on improving electric load recognition thus helping people to better understand their energy consumption.

A BFTree detects events and classifies devices using features extracted with a Fourier Transformation. Combining detection and classification into one algorithm is achieved by introducing the concept of "noise". Our novel approach detects events with 93% accuracy and correctly classifies 88% of the switched on devices. [7]

5.9.2 Artikel im HK Gebäudetechnik

Im Auftrag des BFE wurde ein Artikel über das Projekt REALYSE verfasst, welcher in der Zeitschrift „HK Gebäudetechnik“ und auf der Webseite des BFE veröffentlicht wurde.

Titel:

Ein Messsystem, das die einzelnen elektrischen Geräte erkennt

Autor:

Benedikt Vogel

Lead:

Die meisten Menschen haben keine Vorstellung, wie viel Strom sie zu Hause bei ihren alltäglichen Verrichtungen verbrauchen. Dabei wäre dies eine wichtige Voraussetzung für einen bewussten Umgang mit Energie. Forscher des iHomeLab an der Hochschule Luzern haben ein Analysesystem entwickelt, das aus der Gesamtlastkurve eines Haushalts alle eingeschalteten elektrischen Geräte erkennt und ihren individuellen Verbrauch in Echtzeit misst. [8]

6 Diskussion & Erkenntnisse

In diesem Kapitel wird gezeigt, welchen Mehrwert das im Projekt REALYSE erforschte und entwickelte System für den Benutzer, aber auch für die Umwelt haben kann. Die Ergebnisse sollen aber auch kritisch hinterleuchtet werden, da es noch einige Herausforderungen zu bewältigen gibt. Zudem sind seit dem Start dieses Projekts Produkte auf dem Markt erschienen, die ähnliche Ansätze verfolgen. Auch diese sollen mit Bezug auf REALYSE betrachtet werden.

6.1 Mehrwert für den Benutzer

Durch die in REALYSE ausgeführte Lastaufschlüsselung und die dadurch gewonnenen Informationen kann für den Benutzer eines solchen Systems ein Mehrwert geschaffen werden.

Dank REALYSE können detaillierte Informationen über die aktuelle Leistungsaufnahme aller Geräte im Haushalt gegeben werden. Mit der Zeit kann zudem der Energieverbrauch jedes einzelnen Geräts, und somit dessen Beitrag zu den Elektrizitätskosten angezeigt werden. Mit diesen Informationen kann der Benutzer den Energieverbrauch aktiv und vor allem bewusst beeinflussen und somit Kosten und Energie sparen.

Die Anbindung des REALYSE-Systems an ein Vergleichsportal wie TopTen.ch ermöglicht dem Benutzer den mühelosen Vergleich seiner Geräte mit den jeweils energieeffizientesten Alternativen der entsprechenden Kategorie.

Realisiert haben wir einzig die Anzeige der auf TopTen.ch gelisteten Geräte. Mit einer Weiterentwicklung des Systems wäre es aber möglich, dass vom System automatisch Tipps für effizientere Geräte abgegeben werden, sofern sich ein Ersatz lohnt. Zum Beispiel könnte dann gezeigt werden, ob sich der Ersatz des alten Gefrierschranks lohnt, bzw. innerhalb welcher Zeit die Anschaffungskosten für einen neuen Gefrierschrank durch die eingesparten Energiekosten amortisiert werden können. Dies erleichtert dem Benutzer nicht nur die Entscheidung, sondern hilft im Endeffekt auch Geld zu sparen.

Eine weitere Möglichkeit, wie die Informationen der Lastaufschlüsselung verwertet werden könnten, ist das Erkennen von fehlerhaften Gerätezuständen. So könnte das System darauf aufmerksam machen, wenn zum Beispiel der Gefrierschrank auffällig oft oder gar nie den Kompressor anwirft. Im ersten Fall könnte dies darauf hinweisen, dass die Tür nicht richtig geschlossen wurde, im zweiten Fall kann dies auf einen Defekt des Kompressors hinweisen. In beiden Fällen kann so ein möglicher Verlust des Gefrierguts verhindert werden. Eine solche Anwendung bedarf jedoch einer intelligenten Datenauswertung, welche weitere Forschung und Entwicklung verlangen würde.

Ein weiterer Anwendungsfall, welcher dem Benutzer einen Mehrwert verschafft, ist die Möglichkeit, dass auch von ausserhalb der Wohnung/des Hauses auf die Verbrauchsdaten zugegriffen werden kann. So kann auf der Fahrt in den Urlaub per Smartphone oder Tablet nochmals nachgeprüft werden, ob zum Beispiel der Kochherd tatsächlich ausgeschaltet ist. Dies bedingt aber, dass der Benutzer überhaupt Zugriff auf seine Verbrauchsdaten hat. Dies erfordert entweder, dass sich der Benutzer einen Zugang in sein lokales Netzwerk eingerichtet hat, oder aber dass die Daten auf einem Server im WAN abgelegt werden. Dies könnte durch den Anbieter eines solchen Systems bewerkstelligt werden.

6.2 Beitrag zur Umwelt

Das Ergebnis des Projekts REALYSE entspricht einem System mit Feedback in Echtzeit und einer Aufschlüsselung der Last bis auf die Verbraucherebene. Laut Armel [3] sollte dieses demnach zu einer Reduktion des Energieverbrauchs eines Haushalts um bis zu 12% führen. Sollten solche Systeme tatsächlich zum Einsatz kommen, kann dies durchaus als ein wichtiger Beitrag zur Realisierung der Energiestrategie 2050 betrachtet werden.

6.3 Erkenntnisse

6.3.1 Vorteile der zweistufigen Geräterkennung

Die Aufteilung in zwei Stufen bei der Erkennung erlaubt eine verbesserte Genauigkeit und Erweiterbarkeit des Systems. Die Erkennung in zwei Stufen aufzuteilen, hat zwei Vorteile. Erstens wird durch die kontrollierte Anzahl der zu erkennenden Geräte in der ersten Stufe eine hohe Erkennungsgenauigkeit erreicht. Zweitens müssen Geräte, um in der ersten Stufe erkannt zu werden, nicht trainiert werden. Das System hat bereits ohne zusätzliches Training erfolgreich diverse unbekannte Smartphones in der ersten Stufe als Geräte der „Low Power“-Gerätekategorie erkannt.

6.3.2 Vorteil der Wahrscheinlichkeit in der Erkennung

Eine mit der Erkennung assoziierte Wahrscheinlichkeit verbessert die Eventerkennung signifikant.

Zum Erkennen eines Geräts wurden zwei Strategien getestet. Bei der ersten Strategie wird der Algorithmus mit einer zusätzlichen Klasse namens „Rauschen“ trainiert welche den Zustand beschreibt, wenn kein Event passiert ist. Da die Rauschen-Klasse stark von den laufenden Geräten beeinflusst wird, war die Erkennung dieser Klasse ungenau und damit die Erkennung von Events niedrig.

Bei der zweiten Strategie wird bei jeder Erkennung eine Wahrscheinlichkeit errechnet, welche aussagt wie sicher das Ergebnis ist. Wird dann beispielsweise die Geräteklasse Low Power Devices mit einer Wahrscheinlichkeit von 35% erkannt, gilt das aufgrund der tiefen Wahrscheinlichkeit nicht als Event. Der Vorteil der zweiten Strategie sind eine signifikant höhere Genauigkeit und der geringere Trainingsaufwand. Deshalb konnte sich dieser Ansatz in REALYSE durchsetzen.

6.3.3 Herausforderungen der Geräteerkennung

Das Projekt REALYSE hat nicht nur gezeigt, dass die Lastaufschlüsselung mit NIALM-Algorithmen durchaus machbar ist, sondern hat auch klar die Grenzen dieses Verfahrens aufgezeigt.

Folgend sind die grössten Herausforderungen für die Lastaufschlüsselung gezeigt:

6.3.3.1 Änderung der Leistungsaufnahme im Betrieb

Verbraucher, welche während des Betriebs ihre Leistungsaufnahme ändern stellen eine grosse Herausforderung für die Lastaufschlüsselung dar. Da die Erkennung der Verbraucher eigentlich auf solchen Lastsprüngen basiert, ist es grundsätzlich möglich, auch Zustandswechsel von Verbrauchern während des Betriebs zu erkennen. Hierzu müssten aber alle möglichen Zustandswechsel trainiert werden. Für ein Gerät, welches zum Beispiel neben dem Aus-Zustand drei verschiedene Betriebszustände kennt und von jedem Zustand in jeden anderen Zustand wechseln kann, müssten bereits 12 Zustandswechsel trainiert werden. Dies für alle möglichen Geräte vorzunehmen ist schon alleine von der Anzahl her nicht realistisch.

Werden diese Zustandswechsel aber nicht trainiert, besteht die Gefahr, dass die Lastsprünge als Ein- oder Ausschalten eines anderen Verbrauchers gedeutet werden. Hier zeigt sich, dass die Verwendung eines Qualitätsfaktors unumgänglich ist. Wird also ein Zustandswechsel eines Geräts als Einschaltvorgang eines anderen Geräts gedeutet, dies aber nur mit einer Qualität von 70%, so wird dieses Ereignis verworfen.

Von REALYSE gar nicht erkannt werden langsame Änderungen der Leistungsaufnahme. Solche also, welche in der Erkennung keinen Event generieren.

6.3.3.2 Gleichzeitige Ereignisse

Ein bisher ungelöstes Problem stellen gleichzeitig auftretende Ein- oder Ausschaltereignisse dar. Also dann zum Beispiel, wenn eine Steckdosenleiste mit mehreren daran angeschlossenen Verbrauchern eingesteckt wird und sogleich alle Verbraucher einschalten. Diese gleichzeitig auftretenden Ereignisse können dann nicht den einzelnen Verbrauchern zugeordnet werden und führen zu einer falschen oder gar keiner Erkennung.

Von Seiten der Algorithmen ist diesem Problem nicht beizukommen. Es könnten jedoch Massnahmen getroffen werden um das Auftreten solcher Ereignisse zu reduzieren. Eine Möglichkeit ist die Entwicklung von schaltbaren Steckdosenleisten mit variabler Ein- und Ausschaltverzögerung der einzelnen Steckdosen. So könnten gleichzeitig auftretende Ein-/Ausschaltereignisse verhindert und das Problem der grossen Nullleiterströme beim gleichzeitigen Einschalten mehrerer Verbraucher umgangen werden.

6.3.3.3 Gegenseitige Beeinflussung

Eine weitere Problematik entsteht aus der Kombination der vorgängig erklärten Probleme. Da bereits angeschlossene Verbraucher ihre Leistungsaufnahme, wie bereits erwähnt, stetig ändern können und dies auch geschieht, während neue Verbraucher eingeschaltet bzw. angeschlossen werden, kann die Erkennung der neuen Verbraucher beeinträchtigt werden.

Ist die Leistungsaufnahme des neu angeschlossenen Verbrauchers um Faktoren grösser als die Leistungsänderungen der bereits eingeschalteten Verbraucher, wird dessen Erkennung kaum beeinträchtigt. Es entstehen einzig Ungenauigkeiten bei der Angabe der Leistungsaufnahme.

Im umgekehrten Fall, also wenn der neu angeschlossene Verbraucher um Faktoren kleiner ist als die Leistungssprünge der bereits eingeschalteten Verbraucher, kann die Erkennung beträchtlich gestört oder gar verhindert werden.

Da dies ebenfalls ein Problem gleichzeitiger Ereignisse ist, ist auch diesem von Seiten der Algorith-

men nicht beizukommen. Eine Lösung wäre hier die Trennung von kleinen Verbrauchern und solchen mit grossen Lastsprüngen. Dies ist aber in der Praxis kaum umzusetzen.

6.3.4 Herausforderungen der Datenauswertung

Nicht nur in der Lastaufschlüsselung sind noch Herausforderungen zu bewältigen, sondern auch in der Auswertung der Daten. Dies wird in den folgenden Abschnitten verdeutlicht.

6.3.4.1 Bestimmen des Energiekonsums

Der Energiekonsum eines Verbrauchers wird durch die kontinuierliche Messung der Leistungsaufnahme und anschliessende Integration über die Zeit bestimmt. Bei REALYSE jedoch ist die Leistungsaufnahme eines Verbrauchers jeweils nur zum Zeitpunkt eines erkannten Zustandswechsels bekannt. Wird nun die Energieberechnung basierend auf diesen Daten gemacht, werden nicht erkannte Änderungen der Leistungsaufnahme nicht berücksichtigt, was zu einem sich mit der Zeit aufsummierendem Fehler in der Energieberechnung führt.

In folgendem Beispiel wird dies erläutert:

Der Laserdrucker im iHomeLab Research Center kennt drei Betriebszustände: Aufheizen, Bereitschaft und Standby. Das REALYSE-System wurde dazu trainiert, folgende Zustandswechsel zu erkennen:

- Aus → Aufheizen
- Aufheizen → Bereitschaft
- Bereitschaft → Aus

Der Wechsel in den Standby-Zustand könnte auch trainiert werden. Da dieser aber sehr ähnlich dem Wechsel in den Aus-Zustand ist, wäre die Fehlerrate sehr gross und es wurde darauf verzichtet. So wird der Wechsel in den Standby-Zustand als Wechsel in den Aus-Zustand erkannt. In Abbildung 18 ist die reale Leistungsaufnahme des Druckers und die vom REALYSE-System gemessene Leistungsaufnahme grafisch dargestellt. Da die Leistungsaufnahme jeweils nur bei einem erkannten Zustandswechsel gemessen wird und dann als konstant angenommen werden muss, werden die Fluktuationen nicht erkannt. Der Einfluss auf die Energieberechnung ist in Abbildung 19 deutlich zu sehen.




Abbildung 18: Reale und „gemessene“ Leistungsaufnahme Drucker




Abbildung 19: Realer und berechneter Energiekonsum Drucker

Für einzelne Geräte, welche eine annähernd konstante Leistungsaufnahme besitzen, kann der Energiekonsum jedoch über die Ein- und Ausschaltzeitpunkte bestimmt werden. Es müsste dem System aber während des Trainierens der einzelnen Geräte bekannt gegeben werden, welche Geräte sich für eine Energieberechnung eignen und welche nicht. Bei einer allfälligen Weiterentwicklung des Systems wird dieser Thematik sicherlich nachgegangen.

6.3.4.2 Bestimmung des Energieeffizienzindex

Die automatische Bestimmung des Energieeffizienzindex eines Gerätes benötigt einige Informationen über das Gerät und kann daher nicht ohne weiteres von einem System wie REALYSE gemacht werden.

Einerseits muss bekannt sein, um welche Art Gerät es sich handelt. Also ob es sich um einen Kühlschrank, Wäschetrockner, LED-Leuchtmittel usw. handelt. Dies limitiert eine solche Bestimmung bereits auf die zweite Stufe der Erkennung, bei der die Geräte vom Benutzer trainiert werden.

Zusätzlich müssen dem System einige Kenndaten des Geräts bekannt gegeben werden. Bei einem Kühlschrank ist dies unter anderem das Füllvolumen und ob dieser ein Gefrierabteil besitzt. Weiter wird der Energieeffizienzindex bei den Geräten aufgrund der vom Hersteller angegebenen Leistungsdaten ermittelt. Diese weichen meist von den Leistungsdaten im realen Betrieb ab, da diese von Umgebungsparametern wie der Raumtemperatur, Einbauort usw. abhängt.

Es wäre also viel einfacher, den Energieeffizienzindex eines Geräts zu recherchieren und dann beim Training dem System einzugeben.

Aus diesen Gründen wurde darauf verzichtet, eine automatische Bestimmung des Energieeffizienzindex zu implementieren.

6.3.4.3 Benchmarking

Ähnlich wie mit der Bestimmung des Energieeffizienzindex verhält es sich mit dem Benchmarking, also dem Vergleich der Geräte mit den Besten derselben Kategorie („Best-in-Class“).

Die Anzeige der energieeffizientesten Geräte einer Kategorie kann zwar gemacht werden, wie dies mit der Anbindung der topten.ch-Datenbank realisiert wurde. Für einen effektiven Vergleich müssen aber mehr Daten als der Energieverbrauch bzw. die Leistungsaufnahme eines Geräts verfügbar sein.

Dies soll am Beispiel einer LED-Lampe erläutert werden:

Bereits etwas scheinbar Einfaches wie eine LED-Lampe kann nicht ohne weitere Informationen mit irgendeiner anderen LED-Lampe verglichen werden.

Ein aussagekräftiger Vergleich zweier LED-Lampen kann zum Beispiel über die Anzahl Lumen pro Watt (lm/W), also des pro Watt abgegebenen Lichtstroms, gemacht werden. Da aber LED-Lampen mit grosser Leistung generell einen besseren lm/W-Wert besitzen, muss zusätzlich nach der Leistung kategorisiert werden.

Somit muss, um eine LED-Lampe mit den Energieeffizientesten LED-Lampen zu vergleichen, dem REALYSE-System der spezifizierte Lichtstrom bekannt gegeben werden. Dann muss die LED-Lampe vom REALYSE-System einer Kategorie zugeordnet werden können.

Auf topten.ch werden die LED-Lampe nach Sockel und Lichtstrom (lm) kategorisiert. Die im Demonstrator verwendete LED-Lampe gehört zum Beispiel in die Kategorie „Beleuchtung/LED-Lampen/E27, mittel (<750lm)“. Also wird zusätzlich die Information, dass es sich um einen E27-Sockel handelt, benötigt.

Dieses Beispiel zeigt, dass für ein Benchmarking der Geräte immer zusätzliche Informationen benötigt werden. Diese müssen dem REALYSE-System beim Trainieren auf zweiter Stufe auf irgendeine Weise beigebracht werden.

Eine Lösung wäre die Eingabe der benötigten Informationen über ein GUI. So könnte beim Trainieren der Benutzer aufgefordert werden, die Geräte einer Kategorie, entsprechend der Kategorien auf topten.ch, zuzuordnen.

6.4 Andere Projekte und Produkte

6.4.1 Smappee

Das Produkt „Smappee“ vom gleichnamigen belgischen Unternehmen ist ein Energiemonitor, welcher laut Hersteller „sämtliche wichtigen elektrischen Geräte“ [9] im Haushalt erfasst. Die Geräte können voneinander unterschieden werden, da jedes Gerät „eine einzigartige elektrische Signatur“ [9] besitzt. Die Informationen können dann mit einer App auf dem Smartphone oder Tablet synchronisiert werden.

Smappee verwendet für die Datenakquisition drei Strommessklemmen, welche um die drei Phasen der Haus- oder Wohnungszuleitung zwischen Zähler und Elektroverteiler installiert werden müssen. Daran wird dann der Energiemonitor angeschlossen, welcher zuvor mit einem WLAN verbunden wurde.

Wenn ein Verbraucher eingeschaltet wird, wird dieser von Smappee erfasst und diesem dann eine Nummer zugeordnet. In der App kann dann diese Nummer durch einen Namen, zum Beispiel „Licht Küche“ ersetzt werden. Jetzt sollte jedes Mal, wenn der Verbraucher „Licht Küche“ ein- bzw. ausgeschaltet wird, dieses Ereignis auch diesem Verbraucher zugeordnet und in der App angezeigt werden.

Da man laut Smappee dadurch die „Stromfresser in den Griff“ bekommt und den Wohnraum effizienter nutzt, sollen Einsparungen des Stromverbrauchs von bis zu 30% [9] möglich sein.

Wie genau aus den akquirierten Stromdaten die einzelnen Verbraucher erkannt werden, ist nicht bekannt. Wir vermuten jedoch, dass es die Geräte anhand der Wirk- und Blindleistung (P und Q) erkennen könnte.

Einen zusätzlichen Mehrwert schafft Smappee dadurch, dass mit derselben App zusätzlich erhältliche, schaltbare Zwischenstecker angesteuert werden können.

6.4.1.1 Test

Ein Mitarbeiter des iHomeLab hat Smappee bei sich zu Hause installiert und getestet. Die Installation und Inbetriebnahme waren wie versprochen einfach und schnell erledigt. Die Erkennung der einzelnen Geräte funktionierte aber nicht so gut wie versprochen. So dauerte es laut dem Mitarbeiter mehrere Wochen, bis der Warmwasserboiler als eigenständiger Verbraucher erkannt wurde. Dies jedoch lediglich auf zwei Phasen (der Boiler ist an allen drei Phasen angeschlossen). Eigentlich ist zu erwarten, dass ein solch grosser Verbraucher wie der Warmwasserboiler schnell und zuverlässig erkannt wird. Zudem konnten wir Smappee nicht mit bestimmten Geräten trainieren, obwohl genau das möglich sein soll.

6.4.1.2 Vergleich

Im Gegensatz zu REALYSE kommt Smappee mit weniger Komponenten aus und lässt sich dank der Verwendung von Strommessklemmen auch von einem Laien installieren. Die Benutzerfreundlichkeit lässt sich aber nicht vergleichen, da REALYSE kein fertig entwickeltes Produkt ist.

Bei Smappee gibt es keine Out-of-the-Box Erkennung wie dies bei REALYSE der Fall ist. Dass den einzelnen Verbrauchern zu Beginn einfach Nummern vergeben werden, ist sicher ein guter Ansatz, sofern die Zuverlässigkeit der Erkennung genügend hoch ist und demselben Gerät immer dieselbe Nummer zugeordnet wird und umgekehrt. Das Ersetzen dieser Nummer durch eine Gerätebezeichnung entspricht dem Trainieren der wichtigsten Verbraucher auf der zweiten Erkennungsstufe bei REALYSE.

Das Beispiel mit dem Warmwasserboiler hat gezeigt, dass die Erkennung bei Smappee nicht annähernd so zuverlässig zu funktionieren scheint wie bei REALYSE.

6.4.2 Neurio

Neurio, ein Energiemonitor des kanadischen Unternehmens Neurio Technology Inc. wird gleich wie Smappee mit Strommessklemmen an der Haus- / Wohnungszuleitung angeschlossen. Die Installation ist jedoch leicht komplizierter, da die Energieversorgung direkt ab dem Netz (110V) im Anschlusskasten erfolgt.

Nach der Installation können im Trainingsmodus dem System die einzelnen Verbraucher trainiert werden, indem diese ein- und ausgeschaltet werden. In der App wird sodann angezeigt, dass ein neuer Verbraucher detektiert wurde, woraufhin die Verbraucherdaten eingegeben werden können.

Wie Neurio genau funktioniert und welche Informationen mit diesem System genau gewonnen werden können, ist anhand der Webseite [10] nicht zu ergründen. In einem Video ist jedoch zu sehen, dass dem System auch verschiedene Gerätezustände, zum Beispiel die verschiedenen Stufen einer Mikrowelle, trainiert werden können und diese dann auch erkannt werden.

Auch bei diesem System scheint es keine Out-of-the-Box Erkennung zu geben, weshalb alle Geräte einzeln trainiert werden müssen.

6.4.3 Universität Trier

Das von der Uni Trier vorgestellte System [11] ist von der Architektur her sehr ähnlich aufgebaut, wie unser System in REALYSE: Ein Messknoten erfasst Strom und Spannung mit einer Samplerate um 7kHz. Ein Prozessor (Teensy) berechnet die FFT und leitet die Fourier-Koeffizienten an den nächsten Block weiter. Das ist ein Raspberry Pi, welcher die Klassifizierung und Visualisierung vornimmt.

Die Ergebnisse, welche die Autoren vorstellen zeigen, dass sie mit einem recht einfachen Setup arbeiten. In einem ersten Setup setzen sie einen Ventilator mit drei Stufen und drei Kühlstufen ein. Der von ihnen entwickelte Algorithmus (ein Cluster-Algorithmus) ist allerdings nicht in der Lage, die Ventilatorstufen zu unterscheiden, wenn die Kühlung eingeschaltet ist. Dazu seien die Leistungsaufnahme des Motors und des Kompressors zur Kühlung zu gross. Dasselbe Problem, nämlich die Schwierigkeit, Geräte sicher zu erkennen, wenn gleichzeitig Geräte mit hoher und tiefer Leistungsaufnahme berücksichtigt werden sollen, ist auch im zweiten Setup aufgetreten, wo neun verschiedene Geräte enthalten sind.

Der Ansatz von REALYSE hingegen berücksichtigt von Beginn weg, dass das System einen hohen Dynamikbereich abdecken muss. Daraus resultieren relativ hohe Anforderungen an das Messsystem, welches eine hohe Genauigkeit aufweisen muss. Daher haben wir auf die Strommessung mittels eines Shunt-Widerstandes gesetzt. Diese sind wesentlich genauer als Stromtransformatoren.

Unsere Ergebnisse haben auch aufgezeigt, dass die Clusterbildung, wie sie die Autoren der Uni Trier verwenden, problematisch ist. Der Grund liegt darin, dass durch die Modellbildung einige Informationen verloren gehen (z.B. durch Mittelwertbildung). Der von uns verwendete Algorithmus, der Template Matcher, berücksichtigt alle trainierten Messkurven und bildet keine Mittelwerte. Dadurch kann eine höhere Genauigkeit erreicht werden.

Wir schätzen aufgrund der uns vorliegenden Informationen das REALYSE System als ausgereifter ein.

7 Schlussfolgerungen & Ausblick

7.1 Schlussfolgerungen

Das Projekt REALYSE hatte zum Ziel zu zeigen, dass mit der NIALM-Technologie die einzelnen in einem Haushalt betriebenen Geräte erkannt werden können und dadurch dem Benutzer detaillierte Informationen über seinen Energieverbrauch gegeben werden können. So sollte auch der Energieeffizienzindex der Geräte bestimmt werden können und falls sinnvoll, der Benutzer auf alternative Geräte mit einer besseren Energieeffizienz hingewiesen werden.

Folgend werden die wichtigsten Ergebnisse von REALYSE kurz zusammengefasst und ihr Beitrag zur Zielerreichung aufgezeigt.

Geräteerkennung

Es hat sich gezeigt, dass durch die Aufteilung der Geräteerkennung in zwei Stufen eine sehr hohe Zuverlässigkeit erreicht werden kann. Dem Benutzer kann so eine Erkennung „out-of-the-Box“ geboten werden, wodurch ihm ein Grossteil der Informationen gegeben werden kann, ohne dass er die einzelnen Geräte dem System bekannt geben muss. So muss er für eine detaillierte Erkennung, falls überhaupt gewünscht, nur noch die für ihn wirklich interessanten Geräte trainieren.

Eine Anforderung, mit welcher Zuverlässigkeit die Geräte schlussendlich erkannt werden sollten, gab es im Projekt REALYSE nie. Die Testergebnisse zeigen jedoch, dass eine sehr hohe und somit sicherlich ausreichende Treffsicherheit bei der Erkennung gewährleistet werden kann.

Energieberechnung

Es hat sich gezeigt, dass die Energieberechnung nur für Geräte mit konstanter Leistungsaufnahme mit einer ausreichenden Genauigkeit durchgeführt werden kann. Deshalb wurde dies im Projekt vorerst nicht umgesetzt. Für ein Produkt, welches bei Benutzern zuhause zum Einsatz kommen soll, müsste hierfür eine adäquate Lösung gesucht werden.

Bestimmung des Energieeffizienzindex

Der Energieeffizienzindex kann nicht alleine aufgrund der gemessenen Daten bestimmt werden, sondern verlangt je nach Gerätetyp mehr oder weniger zusätzliche Informationen. Einfacher ist es für den Benutzer, den Energieeffizienzindex der Geräte zu recherchieren und dem System zu übergeben.

Vergleich mit „Best-in-Class“ Geräten

Der angestrebte Vergleich der erkannten Geräte mit den besten ihrer Klasse konnte dank der Anbindung an die topten.ch-Webseite realisiert werden. Hier müsste aber trotzdem noch etwas Entwicklungsaufwand in die Erstellung und Aufbereitung der Informationen gesteckt werden, sodass der Benutzer möglichst schnell sieht, ob sich ein Ersatz bestimmter Geräte lohnt oder nicht.

Alleinstellungsmerkmale

Im Vergleich mit anderen Projekten und Produkten, welche anhand von NIALM-Algorithmen einen detaillierten Überblick über den Energieverbrauch im Haushalt geben sollen, hebt sich REALYSE durch folgende Merkmale von diesen ab:

- Erkennung von Geräteklassen ab Werk
REALYSE ist das einzige System, welches eine Out-of-the-Box Erkennung von Geräteklassen macht.
- Hohe Erkennungsrate
REALYSE wurde auf eine hohe Genauigkeit bei der Erkennung von Verbrauchern getrimmt.
- Vergleich mit Best-in-Class
REALYSE bietet als einziges System einen direkten Vergleich mit den energieeffizientesten Geräten derselben Art.

7.2 Ausblick

7.2.1 Showcase im iHomeLab

Im Anschluss an das Projekt REALYSE werden wir einen Showcase entwerfen und umsetzen, mit welchem die Ergebnisse des Projekts im iHomeLab Visitor Center einem breiten Publikum präsentiert werden.

Ziel des Showcases ist, den Besuchern in kurzer Zeit (ein bis zwei Minuten) zu zeigen, dass mit dem REALYSE System der Energieverbrauch bis auf Geräteebene aufgeschlüsselt werden kann und welche Möglichkeiten daraus entstehen. Der Fokus wird hierbei auf dem Vergleich mit den „Best-in-Class“ Geräten liegen.

Der REALYSE Showcase wird voraussichtlich im zweiten Quartal 2016 lanciert werden.

7.2.2 P&D Projekt

Das Projekt REALYSE hat im Labor sehr vielversprechende Ergebnisse erzielt, es fehlen jedoch Erfahrungen unter realen Bedingungen. Deshalb möchten wir im Anschluss das entwickelte System „im Feld“ erproben. Zu diesem Zweck planen wir, ein vom BFE subventioniertes Pilot- und Demonstrationsprojekt durchzuführen.

In diesem Pilotprojekt sollen die folgenden Ziele verfolgt werden:

1. Die Praxistauglichkeit von Installation und Inbetriebnahme des REALYSE-Systems ist erprobt.
2. Die Usability von REALYSE für den Bewohner ist evaluiert.
3. Die REALYSE Erkennungsrate in einem realen Umfeld ist evaluiert (Zielsetzung für REALYSE unter Laborbedingungen 95%)
4. Der Einfluss der detaillierten Real-Time-Anzeige des Verbrauchs auf das Verbrauchsverhalten über einen längeren Zeitraum ist untersucht (gemäss Literatur kann eine Reduktion von bis zu 12% erreicht werden)

Die Ergebnisse des Pilotprojekts bilden die Grundlage für eine weitere Verbesserung des Systems im Hinblick auf eine mögliche Weiterentwicklung und Markterprobung.

Wir planen die Installation und der Betrieb von REALYSE-Systemen in mehreren Wohnungen. Hierzu müssen wir einerseits die Hardware so weiterentwickeln, dass diese in Elektroverteilern installiert werden kann. Andererseits müssen wir eine Applikation entwickeln, welche den Bewohnern die Bedienung des Systems auf einfachste Weise erlaubt.

8 Referenzen

- [1] A. Energiewirtschaft, «Energieperspektiven 2050,» *Bundesamt für Energie, BFE, Tech. Rep*, 2013.
- [2] Verband Schweizerischer Elektrizitätsunternehmen, «Wege in die neue Stromzukunft (Gesamtbericht),» 2012.
- [3] K. C. Armel, A. Gupta, G. Shrimali und A. Albert, «Is disaggregation the holy grail of energy efficiency? The case of electricity,» *Energy Policy*, Bd. 52, Nr. 0, pp. 213-234, 2013.
- [4] S. Tomek, A. Rumsch und M. Mathis, «Arbeitspaket 1 NIALM Framework / Community,» Horw, 2013.
- [5] Topten International Group, «topten.ch,» 2015. [Online]. Available: www.topten.ch. [Zugriff am 26 11 2015].
- [6] M. Mathis und A. Klapproth, Using a cascading classifier to improve the recognition performance of NIALM, Horw, 2015.
- [7] M. Mathis, P. Huber und A. Klapproth, Recognizing appliances and their events with the same NIALM algorithm, Horw, 2015.
- [8] B. Vogel, «Ein Messsystem, das die einzelnen elektrischen Geräte erkennt,» *HK Gebäudetechnik*, pp. 54-57, 11 2015.
- [9] Smappee, «smappee,» smappee, 2014. [Online]. Available: www.smappee.com/de. [Zugriff am 25 11 2015].
- [10] Neurio Technology Inc., «neurio,» Neurio Technology Inc., 2015. [Online]. Available: neur.io. [Zugriff am 25 11 2015].
- [11] R. Jonetzko, M. Detzler, K.-U. Gollmer, A. Guldner, M. Huber, R. Michels und S. Naumann, High Frequency Non-intrusive Electric Device Detection and Diagnosis, Universität Trier, 2015.
- [12] Bundesamt für Energie, «Energieperspektiven 2050,» Bern, 2013.
- [13] A. Energiewirtschaft, «Energieperspektiven 2050,» *Bundesamt für Energie, BFE, Tech. Rep*, 2013.