Load Disaggregation Anwendungen basierend auf Wirkleistungsmessungen [1]

Dominik Egarter[2]

Abstract: Mit der Hilfe von Smart Metering können wertvolle Informationen über die Gerätenutzung in Haushalten abgerufen werden. Dabei wird mittels Load Disaggregation versucht herauszufinden, welche Geräte benützt werden und wie viel diese Geräte verbrauchen. Diese Dissertation beschäftigt sich mit diesem Thema und präsentiert dabei 3 unterschiedliche Anwendungen, die unterschiedliche Probleme im Bereich Load Disaggregation lösen.

1 Einführung

Es gibt weltweit ein starkes Bestreben den Energiebedarf und dessen Nutzung (bestmöglich) zu optimieren, um die heutige Umwelt zu schonen und demnach die Umweltbelastung zu reduzieren. Die EU hat die 20/20/20 Ziele für Europa in Kraft gesetzt, um erneuerbare Energien zu fördern, die Energieeffizienz zu steigern und den Energiebedarf zu reduzieren. In diesem Zusammenhang ist Smart Metering ein engagiertes Vorhaben für ganz Europa und insbesonders für Österreich, die Energieeffizenz durch ein verbessertes Verbrauchsfeedback zu optimieren. Durch Smart Metering wird es möglich zu erfahren, wann und wie viel Energie verbraucht worden ist. Dieses Wissen kann einerseits dazu verwendet werden das Energiebewusstsein zu verbessern und anderseits den eigenen Energieverbrauch und demnach Kosten zu sparen. Diese zusätzlichen Informationen bzw. das Vorhandensein von Daten des Energieverbrauches eröffnen die Möglichkeit neuer Ansätze des Verbrauchsmanagement, die ohne Smart Metering nicht vorstellbar wäre. Dies und neue Algorithmen zum Erkennen von Mustern in Daten, können dazu verwendet werden den Informationsgrad noch weiter zu steigern. Ein möglicher Ansatz hierzu ist Load Disaggregation bzw. Non-intrusive Load Monitoring (NILM). NILM versucht in diesem Zusammenhang den Hausverhaltsverbrauch auf die Gerätekomponenten mittels eines zentralen Messansatzes (z.B. Smart Metering) mit minimalen Kosten der Messeinheiten herunterzubrechen. Die grundsätzliche Idee von NILM ist es, statistische Informationen des Geräteverbrauches zu nutzen um mittels Algorithmen zum Erkennen von Mustern (Machine Learning), die verwendeten Geräte und dessen Verbrauch aus den Messdaten eines Haushaltes bestmöglich zu schätzen. Non-intrusive Load Monitoring wurde in den 1980ern von George Hart entwickelt und findet in den letzten Jahren immer größeres Interesse in der Forschung und

[1] Englischer Titel der Dissertation: Load Disaggregaton using on Active Power Measurements
[2] Kelag, dominik.egarter@kelag.at

in der Wirtschaft. Die Ansätze und dessen Ergebnisse sind vielfältig und versuchen unterschiedlichste Use Cases und Bedingungen zu erfüllen. In meiner Dissertation 'Load Disaggregation based on Active Power Measurement' habe ich es mir zum Ziel gemacht einen speziellen Anwendungsfall wissenschaftlich zu untersuchen und im weiteren Sinne auch neue Wege und Ideen im Bereich NILM und Energiemanagement zu eröffnen. Diese Arbeit hat sich die Rahmenbedingung gesetzt nur mit Wirkleistungs-Verbräuchen von Haushaltsgeräten zu arbeiten. Die Gerätedaten sind ausschließlich von realen Geräten abgeleitet und es wird eine Sampling-Frequenz von 1 Messwert pro Sekunde verwendet. Unter Berücksichtigung dieser Rahmenbedingungen bearbeitet diese Dissertation drei verschiedene Anwendungen für Non-Instrusive Load Monitoring. Zunächst wird ein einfacher Optimierungsansatz (siehe Load Disaggregation as a Knapsack Model) vorgeschlagen, um das Problem von aggregierten Stromverbrauchern zu lösen. Sechs verschiedene metaheuristische Optimierungsverfahren werden dafür verwendet und mit realen Daten getestet. Um die Komplexität zu beurteilen, befasst sich diese Arbeit mit zwei Komplexitätsmaßen zur Klassifizierung des NILM-Problems (siehe Complexity Analysis of Load Disaggregation). Diese Anwendung wurde durch die Tatsache inspiriert, dass es keine generell übliche Problemdefinition für NILM gibt. Verschiedenste NILM-Ansätze verwenden reale Datensätze mit verschiedenen Vorbearbeitungsstufen und Systemannahmen. Ein fairer Vergleich zwischen verschiedenen NILM-Algorithmen ist daher ohne ein Komplexitätsmaß zur Beschreibung eines NILM-Problems nicht möglich. Schlussendlich führt diese Arbeit auch noch einen neuen unbeobachteten (un-supervised) NILM-Ansatz ein (siehe Unsupervised Approach). Dieser Ansatz funktioniert ohne Systeminformationen und verbessert dieses ständig. Er arbeitet online und ist fähig auf Embedded-Hardware zu laufen. Die drei Ansätze und dessen Ergebnisse werden im Folgenden genauer beschrieben und es wir ein Ausblick gegeben, in welcher Form die gezeigten Ansätzen für weitere Forschung dienen kann und in welcher Form die Ansätze auch außerhalb der Wissenschaft in den realen Haushalten Anwendung finden können.

Es gibt weltweit ein starkes Bestreben den Energiebedarf und dessen Nutzung (bestmöglich) zu optimieren, um die heutige Umwelt zu schonen und demnach die Umweltbelastung zu reduzieren. Die EU hat die 20/20/20 Ziele für Europa in Kraft gesetzt, um erneuerbare Energien zu fördern, die Energieeffizienz zu steigern und den Energiebedarf zu reduzieren. In diesem Zusammenhang ist Smart Metering ein engagiertes Vorhaben für ganz Europa und insbesonders für Österreich, die Energieeffizenz durch ein verbessertes Verbrauchsfeedback zu optimieren. Durch Smart Metering wird es mÖglich zu erfahren, wann und wie viel Energie verbraucht worden ist. Dieses Wissen kann einerseits dazu verwendet werden das Energiebewusstsein zu verbessern und anderseits den eigenen Energieverbrauch und demnach Kosten zu sparen. Diese zusätzlichen Informationen bzw. das Vorhandensein von Daten des Energieverbrauches eröffnen die Möglichkeit neuer Ansätze des Verbrauchsmanagement, die ohne Smart Metering nicht vorstellbar wäre. Dies und neue Algorithmen zum Erkennen von Mustern in Daten, können dazu verwendet werden den Informationsgrad noch weiter zu steigern. Ein möglicher Ansatz hierzu ist Load Disaggregation bzw. Non-intrusive Load Monitoring (NILM). NILM versucht

in diesem Zusammenhang den Hausverhaltsverbrauch auf die Gerätekomponenten mittels eines zentralen Messansatzes (z.B. Smart Metering) mit minimalen Kosten der Messeinheiten herunterzubrechen. Die grundsätzliche Idee von NILM ist es, statistische Informationen des Geräteverbrauches zu nutzen um mittels Algorithmen zum Erkennen von Mustern (Machine Learning), die verwendeten Geräte und dessen Verbrauch aus den Messdaten eines Haushaltes bestmöglich zu schätzen.

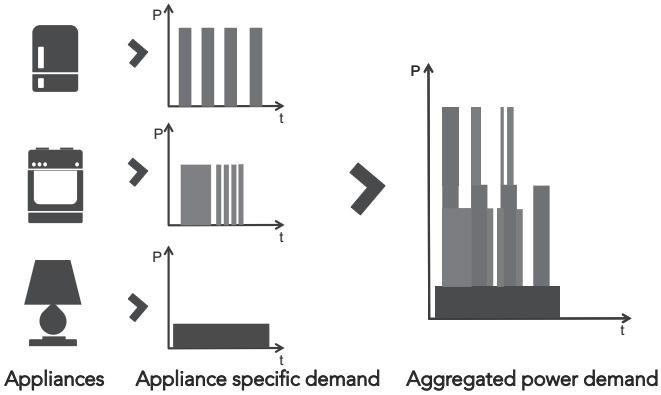

Abb. 1: Konzept von Non-Intrusive Load Monitoring

In Abbildung 1 wird das allgemeine Konzept von NILM veranschaulicht. Dabei werden drei typische Haushaltsgeräte anhand ihres Verbrauchsverhaltens modelliert und dessen typischen Muster im Gesamtverbrauch wiedergefunden. Load Disaggregation wurde in den 1980ern von George Hart entwickelt und findet in den letzten Jahren immer größeres Interesse in der Forschung und in der Wirtschaft. Die Ansätze und dessen Ergebnisse sind vielfältig und versuchen unterschiedlichste Use Cases und Bedingungen zu erfüllen. In meiner Dissertation ”Load Disaggregation based on Active Power Measurement”habe ich es mir zum Ziel gemacht einen speziellen Anwendungsfall wissenschaftlich zu untersuchen und im weiteren Sinne auch neue Wege und Ideen im Bereich NILM und Energiemanagement zu eröffnen. Diese Arbeit hat sich die Rahmenbedingung gesetzt nur mit Wirkleistungs-Verbräuchen von Haushaltsgeräten zu arbeiten. Die Gerätedaten sind ausschließlich von realen Geräten abgeleitet und es wird eine Sampling-Frequenz von 1 Messwert pro Sekunde verwendet. Unter Berücksichtigung dieser Rahmenbedingungen bearbeitet diese Dissertation drei verschiedene Anwendungen für Non-Instrusive Load Monitoring. Zunächst wird ein einfacher Optimierungsansatz (siehe Load Disaggregation as a Knapsack Model) vorgeschlagen, um das Problem von aggregierten Stromverbrauchern zu lösen. Sechs verschiedene metaheuristische Optimierungsverfahren werden dafür verwendet und mit realen Daten getestet. Um die Komplexität zu beurteilen, befasst sich diese Arbeit mit zwei Komplexitätsmaßen zur Klassifizierung des NILM-Problems (siehe Complexity Analysis of Load Disaggregation). Diese Anwendung wurde durch die Tatsache inspiriert, dass es keine generell übliche Problemdefinition für NILM gibt. Verschiedenste NILM-Ansätze verwenden reale Datensätze mit verschiedenen Vorbearbeitungsstufen und Systemannahmen.

Ein fairer Vergleich zwischen verschiedenen NILM-Algorithmen ist daher ohne ein Komplexitätsmaß zur Beschreibung eines NILM-Problems nicht möglich. Schlussendlich führt diese Arbeit auch noch einen neuen unbeobachteten (un-supervised) NILM-Ansatz ein (siehe Unsupervised Approach). Dieser Ansatz funktioniert ohne Systeminformationen und verbessert dieses ständig. Er arbeitet online und ist fähig auf Embedded-Hardware zu laufen. Die drei Ansätze und dessen Ergebnisse werden im Folgenden genauer beschrieben und es wir ein Ausblick gegeben, in welcher Form die gezeigten Ansätzen für weitere Forschung dienen kann und in welcher Form die Ansätze auch außerhalb der Wissenschaft in den realen Haushalten Anwendung finden können.

2 Load Disaggregation as a Knapsack Model

Die grundsätzliche Idee von NILM ist es bekannte Energieprofile so anzuordnen, damit die Summe dieser angeordneten Energieprofile das gewünschte aggregierte Verbrauchsprofil eines Haushaltes ergibt. Im Kapitel 'Load Disaggregation as a Knapsack Model' wird diese Idee verwendet um die leistungsfähige von den heutigen modernen Optimierungsalgorithmen wissenschaftlich zu verifizieren. Dabei wird das NILM-Problem als Rucksack-Problem (knapsack problem) modelliert. Es werden die folgenden 6 metaheuristischen Algorithmen verwendet, um das NILM-Problem zu lösen: Evolutionäre Algorithmus, Simulated Annealing, Differential Evolution, Partical Swarm Optimization, Cuckoo Search Algorithmus und Firefly Algorithmus.

Die Verwendung von metaheuristischen Algorithmen bietet dabei die Möglichkeit mittels 'trial and error' in angemessener Zeit zu einem gewünschten Ergebnis zu kommen. Dabei sind die Algorithmen charakteristisch für deren Randomisierungsteil neue Lösungen zu finden und dem Verwertungsteil die besten Lösungen für die Optimierung weiter zu verwenden. Die Idee in diesem Kapital ist es das Knapsack Model auf das NILM-Problem anzuwenden. Im Allgemeinen versucht das Knapsack Model eine Anzahl von Gegenständen bestmöglich in einen Rucksack mit gegebenem Volumen zu packen. Dabei bekommt man für jeden Gegenstand einen Profit, welchen es zu optimieren gilt ohne die Kapazität des Rucksackes zu übersteigen. Wird nun diese Idee für NILM angewendet, versucht man den Verbrauch von Geräten in ein Verbrauchsprofil bestmöglich mit geringsten Fehlern zu platzieren. Dabei werden alle Geräte und dessen Verbräuche als gleich wichtig bewertet. Das Konzept des Algorithmus ist in Abbildung 2 dargestellt.

Um die Idee nun testen zu können, wurden Gerätedaten von öffentlich zugänglichen Verbrauchsdatensätzen verwendet. Dabei wurden 6 verschiedene Gerätetypen und Verbräuche untersucht. Es wurden zwei Testszenarien verwendet bei welchen die Verbrauchswerte eines Gerätes sich ähnelten oder unterschiedlich waren. Es wurde getestet wie gut ein Optimierungsalgorithmus mit der Tatsache umgehen kann, dass das Verbrauchsverhalten von 2 Geräten im selben Bereich (z.B. 200W und 220W) sein kann. Die Auswertungen zeigten, dass der Algorithmus sehr gut mit

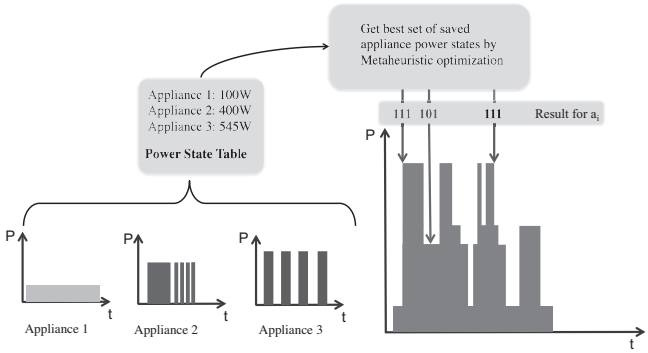

Abb. 2: Konzept zur metaheuristischen Optimierung des NILM-Problems als Rucksackproblem

unterschiedlichen Verbrauchswerten umgehen kann. ähneln sich jedoch Geräte, so ist es nötig neues Wissen und Informationen dem Algorithmus zur Verfügung zu stellen.

2.1 Complexity Analysis of Load Disaggregation

Für die Bewertung von Algorithmen zur Mustererkennung bedarf es einer Metrik um die Ergebnisse vergleichbar zu machen. Möglichkeiten hierbei gibt es einerseits im Bereich der Vergleichsmetriken wie zum Beispiel die True-Positive Bewertung bis hin zur Sensitivität- und Spezifität-Analyse und andererseits die Verwendung von Standardproblemen wie man es aus vielen Bereichen wie Computervision kennt. Im Bereich Load Disaggregation können diese Ansätze angewendet werden, jedoch muss hier die Tatsache berücksichtigt werden, dass unterschiedlichste Algorithmen auch unterschiedliche Bedingungen an die Daten haben und diese günstig für den Algorithmus anwenden. Die Idee in diesem Kapitel ist demnach nicht den Algorithmus und dessen Ergebnis vergleichbar zu machen, sondern das Problem von Load Disaggregation an sich zu beurteilen. Um dies zu lösen wird das Problem anhand des Verbrauches von Geräten und der Tatsache, dass sich das Load Disaggregation Problem durch die Aggregation von diesen Verbrauchswerten über die Zeit bildet, bewertet. Dabei wird anhand der möglichen Verbrauchswerte und dessen Kombination mit anderen Geräten und dessen Verbräuchen, ein Komplexitätswert berechnet. Die Verbrauchswerte von Haushaltgeräten bzw. die Messung dieser Verbrauchswerte sind jedoch nicht zu jedem Zeitpunkt gleich. Die Messwerte sind rauschbehaftet. Um diesen Zusammenhang auch in der Berechnung eines Komplexitätswertes zu berücksichtigen, wird für jeden Verbrauchswert eine Wahrscheinlichkeitsdichte mittels Verbrauchswert und eines angenommenen Rauschwertes gebildet. Der Komplexitätswert verwendet nun diese Wahrscheinlichkeitsdichten und bildet anhand der Schnittflächen mit anliegenden Verbrauchswerten einen Komplexitätswert. Das Konzept der Berechnung ist in Abbildung 3 dargestellt.

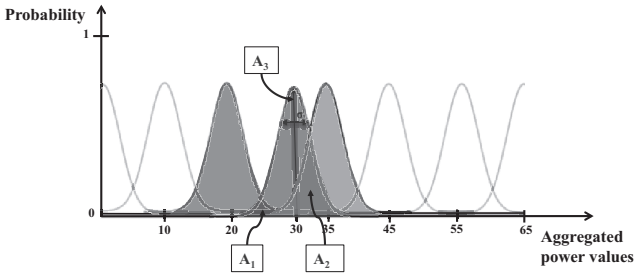

Abb. 3: Prinzip zur Berechnung des Komplexitätswertes

Dabei wird für einen bestimmten Verbrauchswert (Fläche A1) die Schnittfläche mit anderen Verbrauchswerten (Fläche A2 und A3) gebildet. Der errechnet Wert gibt nun an, wie viele ähnliche Verbrauchswerte es gibt einen bestimmten Verbrauchswert zu finden. Die Berechnung dieses Komplexitätswertes wurde für mehrere, öffentlich verfügbare Datensätze und dessen Häuser getestet. Es wurde getestet welcher Datensatz eine höhere Komplexität für Load Disaggregation darstellt. Das Ergebnis dieser Analyse ist in Abbildung 4 dargestellt.

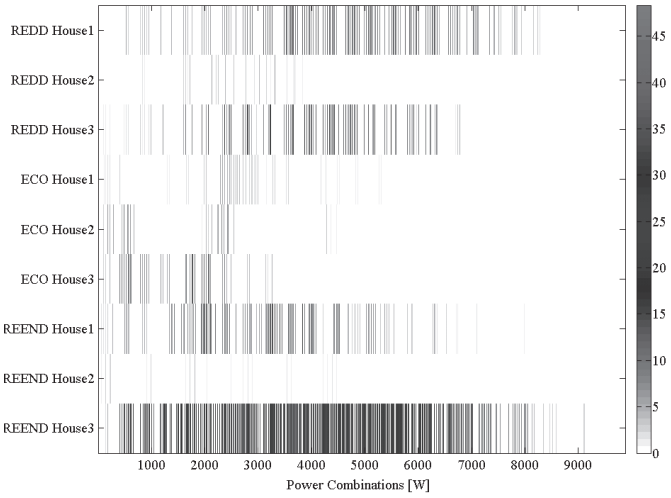

Abb. 4: Komplexitätsberechnung für unterschiedliche Datensätze und Haushaltsverbräuche

Dabei ist ersichtlich, dass je höher der Komplexitätswert, desto schwieriger ist es einen bestimmen Verbrauchswert anhand der möglichen Verbrauchswerte anzunähern bzw. zu erkennen.

Der präsentierte Ansatz kann auch auf gemessene Zeitreihen angewendet werden. Dabei wird nicht ein bestimmter möglicher Verbrauchswert von Geräten verwendet, sondern der aggregierte gemessene Verbrauchswert eines Haushaltes. Abbildung 5

stellt ein Ergebnis dieser Berechnung auf eine Zeitreihe eines Haushaltsverbrauches angewendet dar

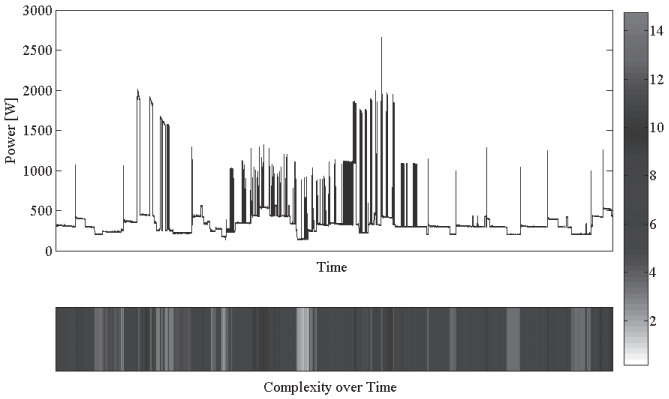

Abb. 5: Komplexitätswerte für eine gemessene Zeitreihe eines Haushaltes

Das vorgestellte Komplexitätsmaß ist unabhängig davon, ob ein Gerät einen oder mehrere Zustände und Verbräuche haben kann. Bedingung ist jedoch, dass diese Verbrauchswerte bekannt sind. Der berechnete Komplexitätswert ist abhängig vom angenommenen Rauschwert. Je genauer dieser bekannt ist, desto besser ist die Aussage des Komplexitätsmaßes.

3 Unsupervised Approach

Eine Vielzahl von Load Disaggregation Ansätzen verwenden Lernphasen und sind darauf ausgelegt offline zu arbeiten. Der in diesem Kapitel präsentierte Ansatz arbeitet online und benötigt keine Lernphasen. Er lernt die Modelle der Geräte während der Laufzeit des Algorithmus und ist demnach ein unsupervised Load Disaggregation Ansatz. Darüberhinaus ist der Algorithmus so ausgelegt, dass er auf kostengünstiger Hardware laufen kann. Vorstellbar hierfür ist z.b. ein Raspberry PI. Die Idee des Algorithmus kann in 4 Teile (siehe Abbildung 6) gegliedert werden: feature detection, state clustering & appliance creation, classification and appliance database update. Dabei werden im Teil 'Feature Detection' die gemessenen Verbrauchsdaten eines Haushaltes analysiert. Es wird versucht mittels 'Edge Detection' fallende und steigende Flanken im Verbrauch zu erkennen. Die erkannten Flanken entsprechen dem Ein- und Ausschaltverhalten eines Haushaltgerätes. Im nächsten Schritt 'State Clustering & Appliance Creation' werden die erkannten Verbrauchswerte geclustert, um Gerätemodelle bilden zu können. Es werden ähnlich steigende und fallende Flanken zusammengefasst und in ein Gerätemodell integriert. Ein Gerät wird in diesem Zusammenhang mittels eines 'Hidden Markov Models' abgebildet. Im nächsten Schritt werden die erkannten Gerätemodelle vom Teil "Classification"verwendet um Geräte im aggregierten Verbrauch eines Haushaltes zu erkennen.

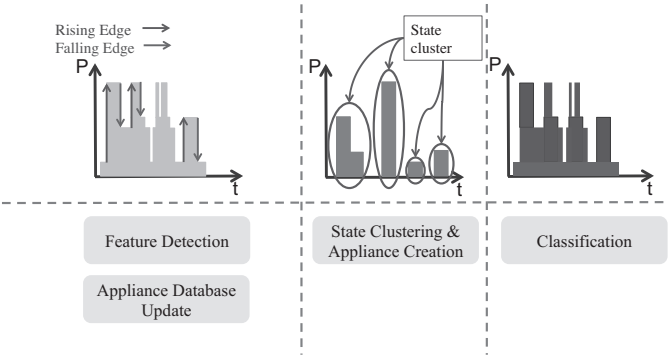

Abb. 6: Darstellung des Unsupervised Ansatzes

Als Klassifizierer wird das Prinzip eines Partikelfilters verwendet. Das Prinzip versucht mittels Gerätemodelle einen Zustandsraum anhand von geschätzten Wahrscheinlichkeitsdichten zu generieren, welcher dazu verwendet wird, den jeweiligen Zustand eines Gerätes zu erkennen. Dieser Prozess verwendet immer den letzten vorhandenen Messpunkt und macht eine Aussage über den aktuellen Status eines Gerätes (im welchen State ist ein Gerät). Das Prinzip ist in Abbildung 7 dargestellt. Wie vorher beschreiben, wird während der Laufzeit im Teil 'Feature Detection' Gerätecharakteristika erkannt und mittels dem nächsten Schritt 'State Clusterin & Appliance Creation' zu Gerätemodellen zusammengefasst. Dieser Prozess wird ständig wiederholt und verbessert. Dabei werden entweder neue Gerätemodelle erkannt oder bereits vorhandenen Gerätemodelle verbessert. Der Prozess wird im Teil 'Appliance Database Update' behandelt. Der Ansatz wurde auf echte, online-verfügbare Daten angewendet und zeigte ein vielversprechendes Verhalten. Es wurden sehr hohe Erkennungsraten von über 90% für den Klassifizierer erreicht. Der Ansatz eignet sich zum Beispiel zur Umsetzung von Energiemanagementsystemen mit in-home Displays, welche ohne die Verwendung von Daten an ein Auswerteservice auskommt. Dabei bekommen Bewohnerinnen und Bewohner ein aktuelles Feedback des Haushaltsverbrauches ohne ihre Daten preisgeben zu müssen.

4 Veröffentlichungen

D. Egarter, V.P. Bhuvana and W. Elmenreich. **PALDi: Online Load Disaggregation based on Particle Filtering**. *IEEE Transactions on Instrumentations and Measurement*, 2014.

T. Khatib, A. Monacchi, W. Elmenreich, D. Egarter, S. D?Alessandro and A. M. Tonello. **European end-user?s level of energy consumption and current structural barriers for smart homes: A case study of residential sectors in Austria and Italy.** *Energy Technology & Policy*, 2014

C. Klemenjak, D. Egarter and W. Elmenreich. **YOMO - The Arduino based Smart Metering Board.** *Computer Science ? Research and Development*, 2015

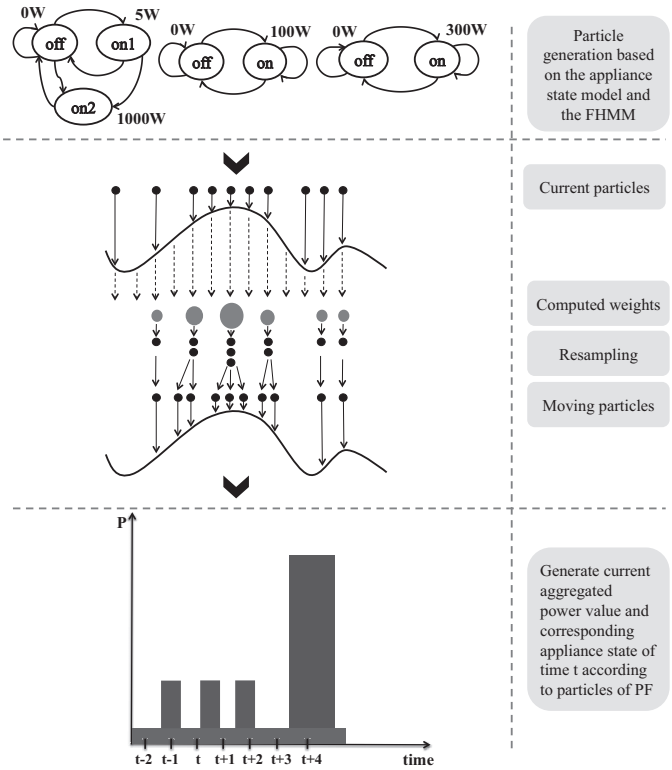

[ht]

Abb. 7: Funktionsweise des Klassifizierungsansatzes

M. Pöchacker, D. Egarter and W. Elmenreich **Proficiency of Power Values for Load Disaggregation.** *IEEE Transactions on Instrumentations and Measurement*, 2016

D. Egarter, A. Monacchi and W. Elmenreich **Integration of Legacy Appliances into the Home Energy Management System.** *Journal of Ambient Intelligence and Humanized Computing*, 2015

A. Reinhardt, G. Konstantinou, D. Egarter and D. Christin **Worried About Privacy? Let Your PV Converter Cover Your Electricity Consumption Fingerprints** *IEEE International Conference on Smart Grid Communication*, 2015

M. Schellander, T. Khatib, W. Elmenreich and D. Egarter. **Techno-economical Assessment of Grid-connected Photovoltaic Power Systems Productivity in Summer Season in Klagenfurt.** *IEEE International Conference on Power and Energy (PECON)*, 2014

C. Klemenjak, D. Egarter and W. Elmenreich. **YOMO - The Arduino based Smart Metering Board.** *Energieinformatik*, 2014

G. Brandner, J. Klinglmayr, D. Egarter, U. Schilcher and C. Bettstetter. **Precision of Pulse-Coupled Oscillator Synchronization on FPGA-Based Radi-**

os. *10th International ITG Conference on Systems, Communications and Coding*, 2015
A. Monacchi, D. Egarter, W. Elmenreich, S. D?Alessandro and A. M. Tonello. **GREEND: an energy consumption dataset of households in Italy and Austria.** *IEEE International Conference on Smart Grid Communication (SmartGridComm)*, 2014.
D. Egarter, C.Prokop and W. Elmenreich. **Load Hiding of Household's Power Demand.** *IEEE International Conference on Smart Grid Communication (SmartGridComm)*, 2014.
D. Egarter, A. Sobe, and W. Elmenreich. **Evolving Non-Intrusive Load Monitoring.** *Proceedings of the European Conference on the Applications of Evolutionary Computation (at EvoStar conference)*, Vienna, Austria, April 2013.
D. Egarter, M. Pöchacker and W. Elmenreich. **Complexity of Power Draws for Load Disaggregation**, Energieinformatik 2016, 2016
D. Egarter and W. Elmenreich. **Autonomous Load Disaggregation Approach based on Active Power Measurements.** *IEEE Workshop on Pervasive Energy Services (PerEnergy)*, 2015
D. Egarter, V.P. Bhuvana and W. Elmenreich. **Appliance State Estimation based on Particle Filtering.** *5th ACM Workshop On Embedded Systems For Energy-Efficient Buildings (BuildSys 2013)*, Rome, Italy, November 2013.
D. Egarter and W. Elmenreich. **EvoNILM - Evolutionary Appliance Detection for Miscellaneous Household Appliances.** *Proceedings of the Workshop on Green and Efficient Energy Applications of Genetic and Evolutionary Computation Workshop (at GECCO conference)*, Amsterdam, Netherlands, July 2013.
A. Monacchi, D. Egarter, and W. Elmenreich.**Integrating Households into the Smart Grid.** *Workshop on Modeling and Simulation of Cyber-Physical Energy Systems (at E-Energy conference)*, Berkeley, CA, May 2013.
W. Elmenreich and D. Egarter. **Design guidelines for smart appliances.** *Proceedings of the 10th International Workshop on Intelligent Solutions in Embedded Systems*, Klagenfurt, Austria, July 2012.
D. Egarter, A. Monacchi, M. Pöchacker, K. Schweiger and B. Steinwender: **Smart Grid: Visionen & Herausforderungen,** published in Energie - Interdisziplinäre Perspektiven auf eine knappe Ressource (Profil Verlag; G. Getzinger, H. Gross)

Dominik Egarter wurde am 30.Dezember 1986 geboren. Er studierte in Klagenfurt, Österreich das Diplomstudium für Informationstechnik, welches er mit Auszeichnung abschloss. Anschließend entschloss er sich ein Doktoratsstudium für Information Technology mit dem Schwerpunkt Smart Metering und Daten-Analysen zu starten. Im 2016 schloss er dieses Studium mit Auszeichnung ab. Heute ist Dominik bei der KELAG in Klagefurt angestellt, wobei seine Arbeitsschwerpunkte im Bereich Smart Metering und Big Data/Daten-Analysen liegen.