개인 맞춤형 에너지 피드백 시스템을 위한 딥러닝 기반의 다수 가전기기 유효전력 분해

김임규¹ · 김현철^{2†} · 신상용³

¹한국과학기술원 기계공학과, 공학박사

²주식회사 아이캡틴, 대표

³주식회사 바이솔라 친환경기술연구소, 연구원

Deep Learning Based Active Power Disaggregation of Appliances for Personalized Energy Feedback System

Kim Imgyu¹ · Kim Hyuncheol^{2†} · Shin Sangyong³

¹Ph.D, Department of Mechanical Engineering, Korea Advanced Institute of Science and Technology

²CEO, iCAPTAIN Co., Ltd

³Researcher, R&D Team, Buysolar Co., Ltd

[†]Corresponding author: ceo@icaptain.kr

Abstract

Energy consumption feedback with an appliance-level feedback system can reduce consumption by a maximum of 12%. In this study, we proposed a data acquisition and training framework for configuring deep learning based on Non-Intrusive Load Monitoring (NILM) for a personalized and appliance-level energy consumption feedback system. To construct a training dataset, an aggregation of active power data from four types of home appliances (refrigerator, induction, TV, washing machine) was performed for approximately three weeks. LSTNet was applied to extract and recognize the features of active power data and the state of each home appliance. With an accuracy metric of more than 90% of the disaggregation result, the applicability of the appliance-level active power feedback system was verified.

Keywords: 비침입 부하 모니터링(Non-Intrusive Load Monitoring), 에너지 분해(Energy disaggregation), LSTNet, 가전기기 단위 피드백 시스템(Appliances level feedback system), 패턴 분석(Pattern Analysis), 인공신경망(Neural Network)

기호 및 약어 설명

E_{acc} : Accuracy metric of disaggregated results compared to measuring data

p : Appliance-level active power (W)

$\hat{p}$: Disaggregated appliance-level active power (W)

T : Total time length (s)

Journal of the Korean Solar Energy Society
Vol.42, No.1, pp.103-114, February 2022
<https://doi.org/10.7836/kjes.2022.42.1.103>

pISSN : 1598-6411

eISSN : 2508-3562

Received: 5 December 2021

Revised: 22 December 2021

Accepted: 26 December 2021

Copyright © Korean Solar Energy Society

This is an Open-Access article distributed under the terms of the Creative Commons Attribution NonCommercial License which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

S : Total number of appliance

상첨자 설명

t : Current time (s)

하첨자 설명

s : Appliance index

1. 연구배경 및 목적

전 세계 에너지 소비의 25 ~ 40%에 상응하는 이산화탄소 배출량은 일반 주거용 건물에서 발생한다¹⁻³⁾. 따라서 탄소배출량을 줄이기 위한 노력의 일환으로 주거/상업용 건물의 에너지 효율을 설계 단계에서 고려하여 에너지 비효율을 야기하는 요소별 최적화를 수행해야만 한다. 이를 위해 정부, 산업계, 연구계의 다양한 분야의 전문가들의 융합 연구 개발이 필수적이며, 일반적으로 이러한 방법은 비용과 시간이 많이 소요된다. 한편, 스마트 미터(Smart meter)와 같은 에너지 효율 개선에 기여할 수 있는 고도화된 에너지 모니터링 시스템을 사용하거나 에너지 소비에 참여하는 소비자가 직접 에너지 효율개선에 참여함으로써 실현 가능하다. 에너지 낭비는 건물의 에너지 소비를 모니터링하고 필요한 조치를 취하기 위해 소비자에게 다시 보고하여 방지할 수 있다. 소비자의 행동은 에너지를 효과적으로 활용하는데 중요한 역할을 한다고 보고되고 있다⁴⁾.

또한 소비자는 에너지 소비 내역에 대한 피드백을 받으면 에너지 사용 패턴을 변경할 가능성이 높다. 최근에는 건물에 스마트 미터를 설치하여 에너지 소비량을 파악할 수 있다. 스마트 미터는 건물의 전체 에너지 소비를 모니터링하고 스마트 미터의 기본 구성에 따라 정기적으로(분/시간/일/주) 또는 지속적으로 소비자에게 에너지 소비에 관한 피드백을 제공할 수 있다. 일반적으로 전체 에너지 소비에 대한 피드백은 에너지 소비를 약 3% 감소시키는 것으로 알려져 있고⁵⁾, 건물 단위 에너지 소비에 대한 실시간 피드백은 약 9%를 절약할 수 있다고 알려져 있다⁴⁾. 그러나 이러한 스마트 미터는 가전기기 단위의 에너지 소비가 아닌 건물 수준의 총 에너지 소비에 대한 정보만으로 에너지 피드백을 제공한다는 한계를 가지고 있다. 따라서 건물 단위 이상의 총 에너지 소비 정보는 소비자의 에너지 사용 패턴을 크게 바꾸는 것은 어려움이 있다⁶⁾. Fig. 1에서는 가전기기 단위의 에너지 소비 피드백이 다른 계획에 비해 최대 12%를 절약할 수 있음을 보여 주고 있다. 이는 개인 맞춤형 에너지 소비 피드백을 위한 필수적인 취득 데이터임을 알 수 있다.

이러한 개인 맞춤형 에너지 소비 피드백을 위해서는 단일 스마트 미터를 통해 건물의 총 전력 소비량을 가전기기 단위로 분해하는 비침입 부하 모니터링(NILM, non-intrusive load monitoring) 기술이 필요하며⁷⁾, 가전기기 단위로 에너지가 분해되어야 한다. 또한 분해가 완료된 결과를 개인의 사용 패턴에 대해 피드백을 주는 추

Fig. 1 Estimated annual energy savings rate by various methods of feedback on energy consumption⁶⁾

천 알고리즘 또는 이상치 감지 알고리즘이 함께 개발되어 하나의 시스템으로 통합 개발되어야 한다. 본 연구에서는 이를 위해 가전 기기 단위의 에너지 분해(energy disaggregation)에 초점을 맞추었다.

NILM 시스템의 에너지 분해는 가전기기 신호의 데이터 패턴에 대한 특징과 가전기기와 스마트 미터의 취합된 전력 신호 간의 관계를 추출하기 위한 특징 추출(feature extraction) 단계와 추출된 특징을 바탕으로 실시간 시계열 에너지 데이터를 회귀(regression)하는 단계로 나뉜다^{8,9)}.

기존의 NILM 기술은 주로 사전에 가전기기 하나씩 전력 패턴을 분석하여 그 패턴을 인식하는 고전적인 특징 추출 기반 분해 방법(Feature Extraction based method)이 사용되었으며, 대표적인 알고리즘은 SVM(Support Vector Machines)¹⁰⁾, HMM(Hidden Markov Models)¹¹⁾ 등이 있다. 가전기기의 고도화, 주거 사용자 패턴의 다각화와 유효한 전력 소비 피드백을 제공하기 위해서는 가전기기와 사용 패턴에 의존성이 적은 딥러닝 기반 접근법이 적절하다고 판단된다. Convolutional Neural Networks(CNN)¹²⁻¹⁴⁾, Recurrent Neural Networks(RNN)^{15,16)} 및 Long Short-Term Memory(LSTM)¹⁶⁻¹⁸⁾, denoising autoencoder (dAE)¹⁹⁾과 같이 최근 딥러닝 기술이 NILM 시스템에 적용된 사례가 보고되고 있다.

본 연구에서는 다변량 시계열 예측(multivariate time series forecasting)을 위해 고안된 Long- and Short-term Time-series network(LSTNet)²⁰⁾을 활용하여 가전기기 4종에 대해 실제 측정 유효전력 데이터를 대상으로 가전기기 단위의 분해를 수행할 수 있는 NILM 프레임워크 구현 방안을 제안한다. LSTNet은 CNN과 RNN을 함께 사용하는 하이브리드 모델(Hybrid model)로써, NILM에서 목표로 하는 특징 추출과 시계열 회귀 및 예측에 적합하다. 논문의 구성은 다음과 같다. 2장에서 데이터셋 구축을 위해 4종 가전기기 전력 데이터 측정을 위한 하드웨어 구성 방법 및 전처리 과정을 기술하였으며, 3장에서 LSTNet의 구조와 각 레이어별 역할을 설명하였고, 4장에서 LSTNet의 학습을 위한 환경과 평가지표에 대한 설명, 그리고 분해 결과에 대한 고찰을 기술하였다.

2. 학습용 데이터셋 구축을 위한 가전기기 전력 데이터 측정

가전기기는 전력 신호 분석 관점에서 크게 3가지 타입으로 나눌 수 있다^{9,21)}. 단일 상태(Single-state, Type1), 다중 상태(Multi-state, Type2) 그리고 무한 상태(Infinite-state 또는 Continuous variational state, Type3) 가 전기기이다. 단일 상태(Type1) 가전기기는 사용자가 on 신호와 off 신호를 명령할 수 있으며 on 명령시 작동 할 수 있는 가전기기의 상태는 1가지 뿐이다. 다중 상태(Type2) 가전기기는 사용자가 on 신호를 입력하면 두 가지 이상의 상태로 작동한다. 좀 더 세분화 하면, 사용자가 ON 신호와 동시에 가전기기의 상태가 결정되는 수동 입력 가전기기와, on 신호를 명령하면 가전기기가 스스로 상태를 변경하면서 작동하는 자동 입력 가전기기로 나눌 수 있다. 사용자가 상태를 수동으로 선택하여 작동 하는 가전기기는 선풍기, 헤어드라이어와 같은 가전기기가 대표적이며, 상태가 스스로 바뀌는 가전기기는 세탁기가 대표적이다. 마지막으로 한번 켜면 꺼질 때까지 작동하면서 일정 상태를 유지하는 것이 아닌 연속적으로 상태를 컨트롤하는 무한 상태(Type3)가전기기가 있다. 가전기기 중 대부분은 일정한 입력 온도를 유지하기 위해 PID 제어기(Proportional-Integral-Differential controller)와 같은 제어 장치가 내장되어 있다. 냉장고, 인덕션, 온도 조절장치가 대표적인 사례이며 특정 온도나 사용자의 입력 값을 유지하기 위해 모터의 RPM을 컨트롤 하게 되거나, 가전기기 내부 저항을 조절하여 전류를 제어하므로 실제로 전력 특성은 가전기기 마다 다른 패턴으로 작동한다. 최근에는 가전기기가 고도화되고 스마트폰 연동 등 사용자 입력 상태와 가전기기의 상태의 복잡도가 증가하는 추세이며, 특히 Type 2와 Type 3가 혼합되어 작동하는 가전기기가 많아지고 있는 추세이다.

NILM 기술의 특성을 고려해보면 각기 다른 타입의 가전기기로부터 다양한 신호가 동시에 취합(Aggregate)되는데, 효율적인 에너지 분해(Disaggregation) 및 NILM을 수행하기 위해서는 모든 가전기기의 상태를 고정하지 않고 분석을 수행해야 하며, 서로 다른 가전기기가 동시에 작동할 때와 독립적으로 작동할 때를 모두 인식할 수 있어야 한다. 따라서 본 연구에서는 Type1, Type2, Type3의 대표적인 가전기기를 모두 포함시키고, 가전기기들의 동시 작동 시간과 가전기기별 독립 작동 시간을 구분하지 않고 데이터셋을 구성하였다. 또한 가전기기의 상태가 변경되면 일정 시간 천이 상태(Transient state)를 거쳐 다음 상태로 넘어가게 되는데, 이를 모두 고려하여 학습할 수 있도록 하였다. 따라서 본 학습용 데이터를 학습하면 작동 중에 여러 타입의 가전기기가 동시에 사용되거나 여러 상태가 복잡하게 뒤섞인 상태가 입력되더라도 신뢰도 높은 에너지 분해 결과를 기대할 수 있다.

본 연구에서는 3가지 타입을 고려하여 가전기기 4개의 에너지 분해를 수행하였다. Type1 가전기기는 TV, Type2는 세탁기 및 인덕션, Type3는 냉장고를 선정하였다. 인덕션의 경우 본 연구에서는 Type2로 분류하였지만, Type3와 혼합된 전기 신호 특성을 가지고 있다. Fig. 2는 3가지 가전기기의 상태에 따른 타입을 나타내고 있으며 Type2는 수동 상태 변경과 자동 상태 변경으로 세분화하여 나타내었다.

Fig. 2 Classification according to the state of appliance

가전기기 전력데이터 수집을 위해 대한민국 경기도 오산에 위치한 5인 가구 아파트 1개 세대의 4대 가전기기의 소비전력을 Fig. 3와 같이 스마트 미터와 함께 구성하여 측정하였다. 스마트 미터의 기본 정보, 하드웨어 명세는 Table 1과 같다. 전력 측정을 위한 중앙 전력 측정장치는 PLC를 통해 이더넷(ethernet) 통신을 활용하여 데이터를 전송하며 가전기기를 개별적으로 연결할 수 있는 콘센트를 전력 측정 장비와 연결하여 각 가전기기별 유효 전력, 4대 가전기기 전체의 유효 전력을 1초 단위로 약 3주 동안 수집하였다.

본 연구에서는 측정된 데이터를 학습 효율성을 증가시키기 위해 전처리를 수행하였다. 가장 먼저 가전 기기가 꺼져 있음에도 잔류전력이 흐르게 되는데 이를 제거 할 수 있는 (minimum threshold)를 25 W로 지정하였다. 그리고 가전제품별로 발생하는 전력 노이즈와 가정에 설치되어 있는 배선 노후 등에 따른 전력 노이즈를 제거를 위해 Low-pass 필터가 필수적이다. 본 연구에서는 Butterworth filter²²⁾를 적용하여 전처리를 수행하였다. 4개 가전기기와 스마트 미터에서 취합한 유효 전력을 함께 도식화하면 Fig. 4와 같다.

Table 1 Overview of Data Acquisition Device (smart meter) and detail specification

Target place	Measurement period	Smart Meter		
Apartment house (5-people household)	20.09.16 ~ 20.10.08 (22 days)	Input	Measurement frequency	50 / 60 Hz
			Voltage input	AC 10 ~ 380 (phase voltage)
			Current input	AC 5A
			Voltage/current	0.5 VA or less (1 Phase)
		Communication	PO	AC/DC 350 V or less (30 VA or less)
			Digital Output	Signal DRY, Normal Open, CB control
		Output	WIFI	Use dedicated manager software
			MODBUS-RTU	RS485 4800 ~ 38400 BPS

Fig. 3 4 types of appliance power measurement diagram with smart meter for a training dataset

Fig. 4 Active power plot of smart meter ("Main" at the figure) and 4 appliances showing a part of the entire training data as a time series after preprocessing

3. NILM 프레임워크를 위한 LSTNet

LSTNet²⁰⁾은 다변량 시계열 예측(multivariate time series forecasting)을 위해 고안된 신경망 프레임워크이다. 이 프레임워크는 CNN 레이어와 RNN 레이어 그리고 Skip-RNN 레이어로 이루어져 있으며 신경망을 통하기 전에 자동 회귀 컴포넌트로 구성된다. 본 연구에서는 NILM 프레임워크의 적용을 위해 입력데이터 차원을 스마트 미터의 데이터, 가전제품의 전력데이터로 수정했으며, 자동 회귀 컴포넌트는 삭제하여 NILM을 위한 LSTNet을 구성했다. 본 연구에서 제안하는 수정된 LSTNet의 구조를 시각화하면 Fig. 5와 같다.

LSTNet의 첫 번째 레이어는 컨볼루션 네트워크로 전력 신호의 시계열 단기 특징과 유효전력과 관계된 측정 데이터(전압, 전류, 피상전력, 무효전력, 역률 등)간의 종속성을 추출하는 역할을 수행할 수 있다. 본 연구에서는 시계열 단기 특징에 초점을 맞추어 진행되었으며 유효전력만을 사용하여 가전기기별 특징을 추출하도록 하였다. 컨볼루션 레이어는 너비 w 와 높이 n 의 필터로 구성되며, 필터의 개수는 하이퍼파라미터로 설정하였다. 필터의 높이(n)는 가전기기의 수와 동일하게 설정해야 특징을 효과적으로 추출할 수 있다. 컨볼루션 레이어에서

기대해볼 수 있는 효과는 다수의 가전기기로부터 복잡도가 높은 상태인 전력 신호와 개별 가전기기의 전력 소비 패턴을 함께 학습하여 그 특징을 효과적으로 추출하는 것이다. 컨볼루션 레이어의 출력 차원은 (필터의 개수 $\times$ 가전기기의 개수 $\times$ 시간)으로 설정할 수 있다.

Fig. 5 An overview of the Long- and Short-term Time-series network (LSTNet) for NILM framework

컨볼루션 레이어에서 출력된 특징 데이터는 순환 레이어(Recurrent layer)와 Recurrent-skip 레이어로 동시에 전달된다. 순환 레이어는 다수의 GRU (Gated Recurrent Unit)²³⁾로 이루어진 순환 레이어이며 활성화 함수로 RELU 함수를 사용한다. 순환 레이어에서 주로 사용되는 대표적인 네트워크 구성 유닛은 GRU²³⁾ 및 LSTM²⁴⁾이 있다. LSTM 또는 GRU 유닛으로 구성된 순환 레이어는 시간 차원으로 학습을 진행하며 과거 정보를 기억하고 상대적으로 장기적인 시계열 종속성을 학습하여 미래 시계열 데이터를 예측할 수 있도록 설계되었다. 그러나 기존의 단순 GRU 및 LSTM은 특징을 추출하는데 어려움이 있음과 동시에, 시계열 데이터 예측을 수행함에 있어서 그라디언트 소실(Gradient Vanishing) 또는 폭주(Exploding)로 인해 실제 계측 데이터에서 장기 기억을 이용한 시계열 예측에는 한계점이 존재한다. LSTNet의 Recurrent-skip 레이어는 이러한 한계점을 극복하기 위해 고안된 레이어이다. 특히 NILM 시스템에서는 주기적으로 On/Off 신호가 불규칙하게 반복된다는 특징이 있는데, 다중 상태 가전기기의 경우 Off 신호를 모두 건너뛰고 On 신호를 주로 장기 기억에 활용하여 장기 상관관계 예측에 효과적으로 활용할 수 있다.

4. LSTNet 학습 및 추론 결과

4.1 학습환경 및 평가지표

LSTNet의 파라미터로써, CNN 필터, GRU 유닛, Recurrent-skip 유닛을 파라미터로 설정해야 한다. 먼저 특징 추출을 위한 컨볼루션 레이어의 필터 개수는 스마트 미터에서 가전기기에 맞는 특징을 추출해내기 위해 필수적으로 최적 파라미터를 도출해야한다. 필터가 적으면 가전기기별 유효한 특징을 추출하기가 어렵고, 필터

가 과도하게 많으면 상태를 대표할 수 있는 유효한 특징과 별개로 유효하지 않은 특징까지 추출하게 되어 이 또한 비효율적이다. 순환 레이어의 GRU 유닛의 개수는 취합된 스마트 미터의 시계열 장기 상관관계를 예측하는데 이용되며, Recurrent-skip 레이어의 스킵 유닛의 개수는 본 연구에서 목표로 하는 4종 데이터셋의 복잡하게 구성되어 있는 가전기기별 상태의 특징을 효과적으로 추출하는데 큰 기여를 할 수 있어 필수 파라미터라고 할 수 있다. 본 연구는 CNN 필터, GRU 유닛, Recurrent-skip 유닛 파라미터를 (200,200,100)으로 설정하여 학습했다. Kolter et al. (2011)²⁵⁾의 연구결과인 평가지표 E_{acc} 는 개별 가전기기의 전체 시간에 대해 오차를 각기 계산하고 집계된 에너지가 제대로 분해되었는지를 평가할 수 있으며 식(1)에 따른다. 학습(Train) 및 검증(Validation) 데이터셋은 시간 기준으로 7:3의 비율로 구성하였다. 학습 환경은 CPU i7 계열 단일 서버, Nvidia RTX-3090 GPU를 사용하였다. 학습 에폭은 100으로 모든 실험에 동일하게 수행하였다.

$$E_{acc} = 1 - \frac{\sum_{t=1}^T \sum_{s=1}^S |\hat{p}_s^t - p_s^t|}{2 \sum_{t=1}^T \sum_{s=1}^S |p_s^t|} \quad (1)$$

4.2 결과

Fig. 6는 100 에폭 학습 후 스마트 미터로부터 측정된 취합 전력 데이터만을 입력하여 최종 추론(Inference)한 결과를 시간 단위로 플롯한 그래프이다. 유효전력의 시계열 그래프를 보면 냉장고와 인덕션, TV, 그리고 세탁기에 대해 on/off 및 다중 상태, 무한 상태를 모두 잘 예측한 것을 볼 수 있다. 평가지표를 기반으로한 정확도는 학습 세트 정확도 $E_{acc} = 0.924$, 검증 세트 정확도 $E_{acc} = 0.902$ 로 나타났다.

냉장고는 꺼져 있는 시간이 없다는 특징과, 특정 온도를 유지하기 위해 모터를 일정 간격마다 작동시키는 특성을 가지고 있다. 본 연구의 결과는 Type3에 대한 상태를 모두 잘 분해 하였음을 알 수 있다. 사용자가 냉동실 문을 열면 냉장고 내부 온도가 일시적으로 상승하게 되는데, 온도를 다시 하강시키기 위해 모터가 일정 시간 빠르게 작동하게 된다. Fig. 6의 첫 번째 그래프의 시간 인덱스 1200 부근을 보면 본 결과는 이러한 갑작스런 가전기기의 상태 변화도 잘 예측 및 분해 하는 것을 알 수 있다.

인덕션은 Type2와 Type3의 특성이 섞여있는 가전제품으로써, 특히 사용자가 특정 온도로 설정 후 그 온도를 사용 중 수시로 바꿀 수 있다. 이러한 불규칙적인 전력 사용량 변화에 대해 상태 인식 및 분해를 잘 수행한 것으로 보인다. 또한 사용자가 레버를 돌려 특정 온도를 설정하면 순간 상승률이 매우 높은 것을 알 수 있다. 본 연구의 학습 모델은 순간 상승률이 높은 가전기기 또한 상태 인식 및 분해를 잘 수행한 것으로 보인다.

TV는 Type1에 속하는 가전기기로써, on/off 상태 변화 지점을 모두 잘 분해 한 것을 알 수 있다. 그러나 실측 전력 소비 패턴은 on 이후 선형적인 형태를 보이게 되는데 본 연구의 추론 결과는 선형이 아닌 일부 노이즈가 발생한 것으로 추론 되었다. 다른 가전기기와 함께 겹쳐지고 취합된 전력신호를 기반으로 추론한 결과이므로 다른 가전기기의 전력 신호의 일부가 TV 신호로 섞여 추론한 것으로 보인다.

Fig. 6 Results of energy disaggregation from aggregated active power measured from smart meter

세탁기 또한 작동 지점을 잘 추론하였으며 작동 이후 자동으로 세탁, 행굼, 탈수 등 스스로 상태를 변화하는 지점도 잘 인식하여 분해한 것으로 보인다. 그러나 Fig. 6 첫 그래프의 Time Index 3300부근에서 세탁기의 전력 신호가 다른 가전제품의 전력신호로 일부 분해된 것을 확인할 수 있다. 이는 세탁기의 전력 스파이크로 인해 발생한 오차로 보이며, 추후 연구로 이상상태(anormal state)를 고려한 에너지 분해 연구가 필수적이다.

5. 결론

본 연구에서는 소비전력 절약을 위한 맞춤형 피드백을 위한 NILM 프레임워크 및 딥러닝 기반의 학습 방법을 제안하였다. 서로 다른 상태를 지닌 가전기기 4종에 대해 3주간 유효전력 데이터를 측정하였다. 실측 데이터를 학습용 데이터로 구성하기 위해 Low-pass filter 등 전처리를 수행하였다. 또한 딥러닝 기반의 시계열 데이터 학습을 통해 복잡한 가전기기의 상태를 추정 및 분해 할 수 있도록 하였다. 다변량 시계열 예측을 위해 고안된 LSTNet 네트워크를 NILM 프레임워크에 적용하였으며, 모든 가전기기에 대해 작동 구간의 인식 및 분해가 효과적으로 이루어져 LSTNet의 유효성을 확인하였다. 학습 데이터 정확도 92.4%, 검증 데이터 정확도 90.2%를 확보했다. 따라서 본 연구를 통해 스마트 미터로부터 취합(agggregation)된 데이터를 입력하여 가전기기 단위의 사용 피드백을 제공할 수 있음을 확인했다. 향후 연구로써 맞춤형 피드백을 효과적으로 제공하기 위하여, 추론 이후 후처리(post-processing) 모듈에 대한 연구를 수행할 예정이다. 후처리 모듈에는 통계적 분석을 기반으로 피드백을 줄 수 있는 모듈과, 본 연구에서 학습한 예측 모델을 기반으로 하여 이상 감지 알고리즘을 적용하여 이상 상태(anormal state)를 고려한 사용자 피드백을 제공할 수 있는 모듈에 대한 연구를 수행할 예정이다.

후기

본 연구는 국토교통부/국토교통과학기술진흥원의 지원을 받아 수행한 연구 과제입니다(No. 20CTAP-C15 7743-01).

REFERENCES

1. Elma, O. and Selamoğullar, U. S., A Survey of a Residential Load Profile for Demand Side Management Systems, 2017 IEEE International Conference on Smart Energy Grid Engineering (SEGE), pp. 85-89, 2017, doi: 10.1109/sege.2017.8052781.
2. Mostafavi, S. and Cox, R. W., An Unsupervised Approach in Learning Load Patterns for Non-intrusive Load Monitoring, 2017 IEEE 14th International Conference on Networking, Sensing and Control (ICNSC), pp. 631-636, 2017, doi: 10.1109/icnsc.2017.8000164.
3. Pérez-Lombard, L., Ortiz, J., and Pout, C., A Review on Buildings Energy Consumption Information, Energy and Buildings, Vol. 40, No. 3, pp. 394-398, 2008, doi: 10.1016/j.enbuild.2007.03.007.
4. Armel, K. C., Gupta, A., Shrimali, G., and Albert, A. Is Disaggregation the Holy Grail of Energy Efficiency?,

- The Case of Electricity, *Energy Policy*, Vol. 52, pp. 213-234, 2013.
5. Davis, A. L., Krishnamurti, T., Fischhoff, B., and Bruine de Bruin, W., Setting a Standard for Electricity Pilot Studies, *Energy Policy*, Vol. 62, pp. 401-409, 2013, doi: <https://doi.org/10.1016/j.enpol.2013.07.093>.
6. Hazas, M., Friday, A., and Scott, J., Look Back before Leaping Forward: Four Decades of Domestic Energy Inquiry, *IEEE Pervasive Computing*, Vol. 10, No. 1, pp. 13-19, 2011, doi: 10.1109/MPRV.2010.89.
7. Hart, G. W., Nonintrusive Appliance Load Monitoring, *Proceedings of the IEEE*, Vol. 80, No. 12, pp. 1870-1891, 1992, doi: 10.1109/5.192069.
8. Schirmer, P. A., Mporas, I., and Sheikh-Akbari, A., Energy Disaggregation using Two-stage Fusion of Binary Device Detectors, *Energies*, Vol. 13, No. 9, p. 2148, 2020.
9. Gopinath, R., Kumar, M., Joshua, C. P. C., and Srinivas, K., Energy Management using Non-intrusive Load Monitoring Techniques-State-of-the-art and Future Research Directions, *Sustainable Cities and Society*, Vol. 62, 102411, 2020.
10. Hassan, T., Javed, F., and Arshad, N., An Empirical Investigation of VI Trajectory based Load Signatures for Non-intrusive Load Monitoring, *IEEE Transactions on Smart Grid*, Vol. 5, No. 2, pp. 870-878, 2013, doi: 10.1109/pesgm.2014.6938824.
11. Bonfigli, R. and Squartini, S., HMM Based Approach, *Machine Learning Approaches to Non-intrusive Load Monitoring*, Springer, pp. 31-90, 2020.
12. Murray, D., Stankovic, L., Stankovic, V., Lulic, S., and Sladojevic, S., Transferability of Neural Network Approaches For Low-rate Energy Disaggregation, *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 8330-8334. doi: 10.1109/icassp.2019.8682486.
13. Said Barsim, K. and Yang, B., On the Feasibility of Generic Deep Disaggregation for Single-load Extraction, *arXiv e-prints*, pp. arXiv: 1802.02139, 2018.
14. Wu, X., Han, X., and Liang, K. X., Event-based Non-intrusive Load Identification Algorithm for Residential Loads Combined with Underdetermined Decomposition and Characteristic Filtering, *IET Generation, Transmission & Distribution*, Vol. 13, No. 1, pp. 99-107, 2019, doi: 10.1049/iet-nbt.2019.0335.
15. Çavdar, İ. H. and Faryad, V., New Design of a Supervised Energy Disaggregation Model based on the Deep Neural Network for a Smart Grid, *Energies*, Vol. 12, No. 7, p. 1217, 2019, doi: 10.3390/en12071217.
16. He, W. and Chai, Y. An Empirical Study on Energy Disaggregation via Deep Learning, *Advances in Intelligent Systems Research*, Vol. 133, pp. 338-342, 2016, doi: 10.2991/aiie-16.2016.77.
17. Mauch, L. and Yang, B. A New Approach for Supervised Power Disaggregation by using a Deep Recurrent LSTM Network, *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, pp. 63-67. doi: 10.1109/globalsip.2015.7418157.
18. Kim, I. K., Kim H. C., Kim S. Y., and Shin S. Y., Spectrogram Analysis of Active Power of Appliances and LSTM-based Energy Disaggregation, *Journal of the Korea Convergence Society*, Vol. 12, No. 2, pp. 21-28, 2021.
19. Garcia, F. C. C., Creayla, C. M. C., and Macabebe, E. Q. B., Development of an Intelligent System for Smart Home Energy Disaggregation using Stacked Denoising Autoencoders, *Procedia Computer Science*, Vol. 105, pp. 248-255, 2017, doi: 10.1016/j.procs.2017.01.218.
20. Lai, G., Chang, W.-C., Yang, Y., and Liu, H., Modeling Long-and Short-Term Temporal Patterns with Deep Neural Networks, *The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval*, pp. 95-104, 2018.
21. Salem, H., Sayed-Mouchaweh, M., and Tagina, M., A Review on Non-intrusive Load Monitoring Approaches based on Machine Learning, *Artificial Intelligence Techniques for a Scalable Energy Transition*, Springer, pp.

- 109-131, 2020.
22. Butterworth, S., On the Theory of Filter Amplifiers, *Wireless Engineer*, Vol. 7, No. 6, pp. 536-541, 1930.
 23. Chung, J., Gulcehre, C., Cho, K., and Bengio, Y., Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling, *arXiv preprint arXiv:1412.3555*, 2014.
 24. Hochreiter, S. and Schmidhuber, J., Long Short-term Memory, *Neural Computation*, Vol. 9, No. 8, pp. 1735-1780, 1997.
 25. Kolter, J. Z. and Johnson, M. J., REDD: A Public Data Set for Energy Disaggregation Research, *Workshop on Data Mining Applications in Sustainability (SIGKDD)*, San Diego, CA, Vol. 25, pp. 59-62, 2011.