Journal of the Korea Convergence Society
Vol. 12. No. 2, pp. 21-28, 2021

ISSN 2233-4890 / eISSN 2713-6353
https://doi.org/10.15207/JKCS.2021.12.2.021

다수 가전기기 유효전력의 스팩토그램 분석 및 LSTM기반의 전력 분해 알고리즘

김임규[1], 김현철[2*], 김승윤[3], 신상용[4]
[1]한국과학기술원 기계공학과 박사과정, [2]주식회사 아이캡틴 대표, [4]주식회사 바이솔라 연구원

Spectogram analysis of active power of appliances and LSTM-based Energy Disaggregation

Imgyu Kim[1], Hyuncheol Kim[2*], Seung Yun Kim[3], Sangyong Shin[4]
[1]Ph.D Candidate, Department of Mechanical Engineering, KAIST
[2]CEO, iCAPTAIN Co., Ltd.
[4]Researcher, BuySolar Co., Ltd.

요 약 본 연구에서는 가전기기 5종에 대해 실제 측정 전력 데이터를 이용하여 딥러닝 기반의 NILM 기법을 제안하고 그 효용성을 검증 하고자 한다. 약 3주간 중앙 전력 측정 장치 및 5종 가전기기(냉장고, 인덕션, TV, 세탁기, 공기청정기)의 유효전력을 개별 측정하였다. 실측 데이터의 전처리 방법을 소개하고 Spectogram 분석을 통해 가전 기기별 특징을 분석하였다. 가전기기별 특징을 학습 데이터셋으로 구성하였다. 중앙 전력 측정 기기와 가전기기 5종에서 측정된 모든 전력 데이터를 시계열 매핑하여 시계열 데이터 분석에 우수한 RNN 계열의 LSTM 신경망을 이용해 학습을 수행하였다. 메인 중앙 전력 측정 장치의 전력 데이터만으로도 5종 전력 신호를 분해해낼 수 있는 알고리즘을 제안하였다.

주제어 : 에너지 분해, 비침입 부하 모니터링(NILM), LSTM, 스마트 그리드 시스템, 스팩토그램

Abstract In this study, we propose a deep learning-based NILM technique using actual measured power data for 5 kinds of home appliances and verify its effectiveness. For about 3 weeks, the active power of the central power measuring device and five kinds of home appliances (refrigerator, induction, TV, washing machine, air cleaner) was individually measured. The preprocessing method of the measured data was introduced, and characteristics of each household appliance were analyzed through spectogram analysis. The characteristics of each household appliance are organized into a learning data set. All the power data measured by the central power measuring device and 5 kinds of home appliances were time-series mapping, and training was performed using a LSTM neural network, which is excellent for time series data prediction. An algorithm that can disaggregate five types of energies using only the power data of the main central power measuring device is proposed.

Key Words : Energy disaggregation, NILM(Non-Intrusive Load Monitoring), LSTM, Smart Grid System, Spectogram

*This work is supported by the Korea Agency for Infrastructure Technology Advancement(KAIA) grant funded by the Ministry of Land, Infrastructure and Transport (Grant 20CTAP-C157743-01).
*Corresponding Author : Hyuncheol Kim(ceo@icaptain.kr)
Received December 24, 2020 Revised January 19, 2021
Accepted February 20, 2021 Published February 28, 2021

1. 서론

전 세계 에너지 소비의 25~40 %에 상응하는 이산화탄소 배출량은 일반 주거용 건물에서 발생한다[1-4]. 주거용 건물 또는 가정에서 사용되는 전기 장치의 개수 또한 스마트 디바이스와 가전기기의 고도화로 인해 증가할 것으로 예상된다. 한편 가정에서 사용되는 에너지 소비의 약 20%가 가전기기의 결함 또는 불량으로 인해 누전과 비효율적인 운용으로 인한 것으로 조사되었다[5-7]. 따라서 결함이 있는 가전기기를 능동적으로 모니터링하고 가전기기별 운용 전략을 개선하기 위해 최적 및 차선의 운용 전략을 찾기 위해 장치 감지 및 부하 스케줄링 최적화 기술이 최근 핵심 기술로써 연구가 수행되고 있다[8].

하나의 마스터 전력 측정기로부터 개별 가전기기의 전력을 분해 및 분석하는 시스템을 위한 스마트 그리드 시스템 및 스마트 디바이스 또한 상당한 기술 진보를 이루었다[8,9]. 가정에서 측정되는 개별 가전 기기별 에너지 사용량을 모니터링하게 되면 가전 기기별 최대 부하를 줄일 수 있어 가전기기의 결함을 줄일 수 있을 뿐만 아니라 전체적인 에너지 소비량을 효율적으로 설계 할 수 있다[10].

Table 1. Central main power measurement equipment

Target place			Apartment(Osan, South Korea), 5-person household
Measurement period			20.09.16 ~ 20.10.08 (22 days)
Main Centered Measuring Device	Input	Measurement freq	50 / 60 Hz
		Voltage input	AC 10 ~ 380 (phase voltage)
		Current input	AC 5A
		Voltage/ current	0.5 VA or less (1 Phase)
	Output	WIFI	Use dedicated manager software
		MODBUS-RTU	RS485 4800 ~ 38400 BPS
	images		

그러나 오늘날 전력 사용량 모니터링의 수준은 대부분 월별 청구서에 대한 총 에너지 측정을 통해 수행되며 가전 기기별 사용량에 대한 정보는 전혀 주어지지 않고 있다. 이를 위해서는 에너지 소비를 정확하게 측정하기 위해 일반적으로 1Hz 이상의 샘플링 해상도를 가지는 스마트 미터가 필수적이다. 스마트 미터는 전압 및 전류 측정을 기반으로 가전기기의 에너지 소비를 측정하는 데 사용되는 장치이다. 스마트 미터의 에너지 측정 주기가 작을수록 에너지 소비 패턴 또는 특징적 요소를 파악하기 쉬 울 수 있다. 그러나 과도한 샘플링 주파수의 증가는 데이터의 저장, 처리 시간이 기하급수적으로 증가 할 수 있을 뿐만 아니라 가전기기와는 상관없는 전력 측정 데이터에 미치는 노이즈 요소들이 많이 측정되어 분석 정확도를 떨어뜨릴 위험성이 있다[11]. 따라서 적절한 측정 주기를 설정할 필요가 있으며 대부분의 상업용 스마트 미터는 하드웨어 비용, 데이터 전송 및 저장의 용이함 그리고 분석 정확도를 최적으로 설정 할 수 있도록 일반적으로 0.1Hz 또는 최대 1Hz 정도의 주파수로 데이터를 취득한다[13,14].

에너지 분해(Energy Disaggregation)는 전체 가정 부하의 전류 및 전압을 측정하여 개별 기기에서 에너지 소비량을 거시적으로 측정하거나 시계열의 형태로 Regression 하는 기술을 비침입 부하 모니터링 (Non-Intrusive Load Monitoring, NILM)이라고 한다[12]. 비침입적(Non-Intrusive)이라는 용어는 다수의 전력 측정 장치 또는 개별 가전기기에 따로 부착된 스마트 미터를 활용하는 기존의 ILM (Intrusive Load Monitoring) 방법과 차별을 두기 위해 사용하는 용어이며 하나의 메인 측정 장치로부터 계측되는 가전 기기의 총 사용량을 분석하여 가전 기기별 패턴을 포착 및 분류, 사용량 예측까지 수행할 수 있다는 점에 큰 차이점이 있다. NILM은 하나의 중앙 측정을 기반으로 가전 기기 수준으로 전기 에너지 소비를 추출하므로 집계 된 총 에너지 신호에서 가전 기기의 시작 신호(스위치 On) 및 사용 종류 시간(스위치 Off)을 식별하여 기기를 식별 하였다[15].

NILM 기술은 SS (Source Separation) 알고리즘을 사용하는 방법과 SS 알고리즘을 사용하지 않는 방법으로 가장 크게 분류된다. NILM 방법은 주로 샘플링 주파수에 따라 거시 신호 기반 파라미터(예 : 유효/무효 전력 [16]) 또는 미시 신호 파라미터 (예 : 과출력 에너지 및 고조파 [17])를 사용하여 가전 기기 수준으로 전력량을 분석 할 수 있다는 장점이 있다. SS 알고리즘을 사용하지 않는 방법은 주로 특징 추출 기반 기법(Feature Extraction based method)이 사용되며, 머신 러닝 알고리즘 (예 : SVM (Support Vector Machines) [18], 인공 신경망 (ANN) [19], Decision Tree (DT) [20], K-Nearest Neighbors (KNN) [21]) 기법이 주로 사용된다. 이는 여러 가지 이유로 실제 가정이나 건물에서 사

Table 2. Types and specifications of appliances connected to the central main power measuring device

Appliances	Refrigerator	Induction	TV	Air Cleaner	Washer
Power	33kWh/Month	3400W	180W	38W	2100W
Voltage	-	220V	240V	100~240V	220V
Frequency	-	60Hz	50/60Hz	50/60Hz	60Hz
Dimension	912x1785x910 (mm)	575x515x54 (mm)	65 (inches)	44.5 (m^2)	645x770x940 (mm)
Images					

용하기엔 제약요소가 있다. 가전기기의 빠른 고도화와 On/Off 외에 다른 신호가 있는 가전기기, 그리고 냉장고와 같이 항상 켜져 있는 가전기기의 경우에는 분석이 효율적으로 이루어지지 않는다. 최근에는 SS 알고리즘을 함께 사용하는 딥러닝 기반의 NILM 기법이 보고되고 있으며 기존 기계학습 기반의 한계점을 여러 측면에서 뛰어넘고 있다. CNN(Convolutional Neural Networks) [22,23,24], RNN (Recurrent Neural Networks) [25,26] 및 LSTM(Long Short-Term Memory) [26,27], denoising autoencoder (dAE) [28]를 사용하는 방법론, GRU (Gated Recurrent Units) [22] 등이 있다.

본 연구에서는 가전기기 5종에 대해 실제 측정 전력 데이터를 이용하여 딥러닝 기반의 NILM 기법을 제안하고 그 효용성을 검증하려 한다. 실측 데이터에서 전처리 방법을 소개하고 Spectogram 분석을 통해 가전 기기별 특징을 추출하여 분해 성능을 향상시켰다. 또한 중앙 전력 측정 기기와 가전 기기 5종에서 측정된 모든 전력 데이터를 시계열 매핑하여 시계열 데이터 분석에 우수한 RNN 계열의 LSTM 신경망[26,27]을 이용해 학습을 수행했다. 추후 main 전력 기기의 전력 데이터만으로도 5종 전력 신호를 분해해낼 수 있는 알고리즘을 제안한다.

2. 전력 데이터 측정

국내 주택 유형은 단독주택, 아파트, 연립 및 다세대, 기타로 분류할 수 있으며, 월평균 전력사용량 소비 구조는 아파트에서 51%로 가장 높은 비율을 차지하고 있다 [29]. 본 연구는 가전기기 전력 데이터 수집을 위해 경기도 오산에 위치한 5인 가구 아파트 1개 세대의 5대 가전기기의 소비전력을 Table 1. 과 같이 측정했으며, 가전기기별 세부사항은 Table 2. 와 같다. 전력 측정 장비는 PLC를 통해 이더넷(ethernet) 통신으로 데이터를 전송하며, 100ms 단위 샘플링이 가능하다. 가전기기를 개별적으로 연결할 수 있는 콘센트를 전력 측정 장비와 연결하여 가전기기별 유효 전력, 5대 가전기기 전체(메인)의 유효 전력을 1초 단위로 약 3주 동안 수집하였다.

본 연구에서 측정한 가전기기는 냉장고, 인덕션, TV, 공기청정기, 세탁기이며 24시간 전력 사용량을 메인 전력 데이터와 함께 도식화하면 Fig. 1과 같다

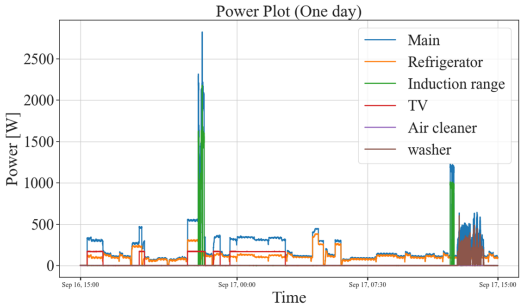

Fig. 1. Active power consumption for one day each appliance.

3. 스팩토그램을 이용한 전력 데이터 분석

스팩토그램(Spectogram)이란 FFT(Fast Fourier Transform)를 활용하여 전력 데이터를 시간-주파수 영역대별 분포도 시각화한 자료이다. Fig. 1에 나타난 모든 가전기기를 스팩토그램으로 도식화하면 Fig. 2와 같다. 스팩토그램 분석 결과 각 가전기기의 특징을 시각적으로 파악할 수 있다. On/Off 신호가 명확한 가전기기, 작동(On)중 유효전력 변동 주파수대역이 저주파~고주파로 넓은 영역으로 분포하는 기기, 특정 주파수대에 에너지가 분포하는 기기 등 다양한 특징을 추출 할 수 있다.

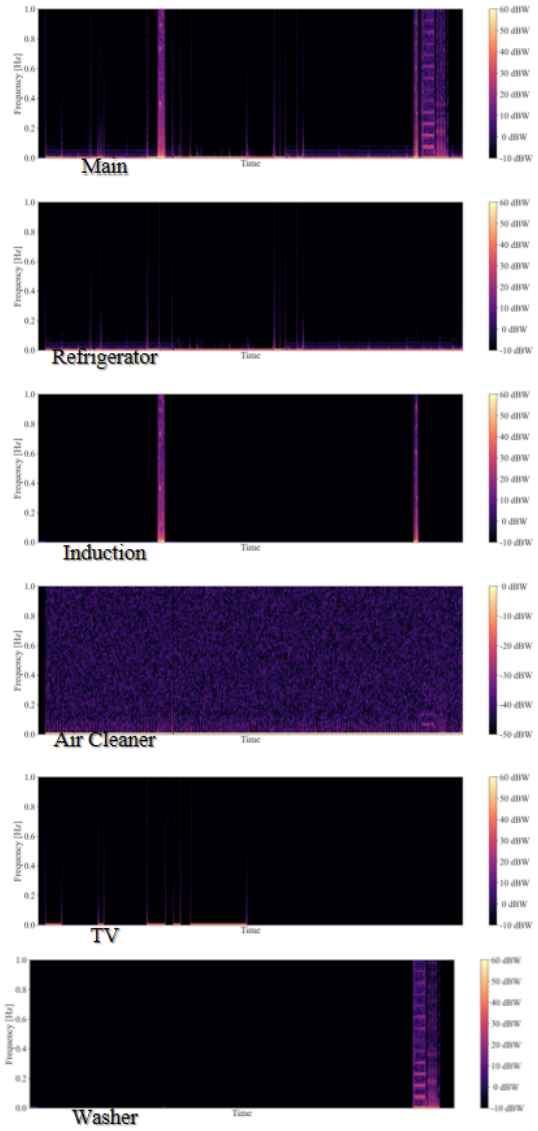

Fig. 2. Spectogram analysis result for each home appliance.

스팩토그램의 전력 단위는 dbW를 사용하였고, 기간은 Fig. 1의 기간과 같은 기간으로 가시화하였다.

TV, 세탁기, 인덕션의 경우에는 On/Off 신호가 명확하다는 특성이 있다. 인덕션 및 세탁기는 0~1.0Hz 주파수 넓은 영역에서 고루 전력 에너지가 분포하였다. 공기청정기의 경우에는 On/Off 신호가 명확하지 않으며 항상 대기 전력이 존재 하는 것을 알 수가 있으며 On 신호 시에는 간헐적으로 전력 신호가 증가 하는 것을 확인할 수 있었다. TV의 경우에는 On 신호시 전력 소모량은 냉장고와 비슷하지만 스팩토그램 분석 결과 저주파수의 전력 소모가 이루어졌다. 냉장고는 항상 켜진 상태로 사용한다는 특징이 있는데, 스팩토그램 분석 결과 냉장고 내부 온도 유지를 위해 모터가 가동될 때마다 전력 소모가 증가하는 것을 확인할 수 있으며 저주파수대에 에너지가 집중되어 있다는 것을 알 수 있다.

4. 딥러닝 기반의 전력 분해 알고리즘

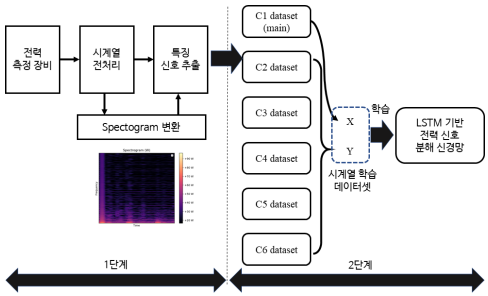

Fig. 3. Spectogram and LSTM-based energy disaggregation algorithm.

본 연구에서 제안하는 전력 분해 알고리즘은 2단계로 구성되어 있다. 측정된 전력 데이터를 전처리를 수행하고 스팩토그램 분석을 통해 특징 신호를 추출한다. 메인 전력 측정 장치를 포함한 5개 가전기기를 하나의 학습 데이터셋으로 구성하여 LSTM 기반의 신경망 학습을 수행하였다. 메인 전력 측정 장치에서 취합된 전력 데이터는 아래의 식으로 표현될 수 있다.

$$P_{agg} = f(p_1, p_2, \cdots, p_s, p_g) = \sum_{s=1}^{S} p_s + p_g$$

P_{agg}는 메인 전력 측정 장치에서 취합된 S개의 가전기기의 유효전력이고 $p_1, p_2, \cdots, p_s$는 개별 가전기기별로 측정되는 유효전력이다. p_g는 개별 가전기기의 유효전력 외에 측정되는 전력 데이터이다. 이는 하드웨어에 연결된 물리적 결함으로 인해 발생하는 전력 손실, 가전기기와 메인 측정 장치가 작동하는 주변 환경 등에 의해 발생하는 메인 측정 장치의 오차 전력 값이다.

본 연구에서 제안하는 전력 분해 알고리즘은 메인 전력 측정 장치에서 측정된 P_{agg}에서 $p_1, p_2, \cdots, p_s$신호를 추출해내는 것이 목적이라 할 수 있다.

$$\{\hat{p_1}, \hat{p_2}, \cdots, \hat{p_s}\} = f^{-1}(P_{agg}) = \hat{P}$$

$\{\hat{p}_1, \hat{p}_2, \cdots, \hat{p}_s\}$은 P_{agg}로부터 분해 알고리즘을 거쳐 분해된 가전기기 전력이다. 본 전력 분해 알고리즘은 아래 식을 만족하는 해를 찾는 함수에 대한 알고리즘으로 정의 할 수 있다.

위 식에 대한 해석해를 찾는 것은 어려움이 있어 대부분의 전력 분해 알고리즘은 전력 신호를 시간 단위로 분해하여 기계학습 기반의 모델을 이용하여 전력 장치 레벨에서 추정하는 방식을 사용해 왔다. 본 연구에서는 전력 데이터를 “One to many” 학습 데이터 형식으로 매핑하여 LSTM 기반의 방법으로 이를 해결하고자 한다.

Fig. 4는 본 연구에서 LSTM 신경망 학습을 위해 수행된 데이터 전처리 프로세스이다. 데이터 전처리는 Raw 데이터를 딥러닝 알고리즘에 알맞은 학습 데이터셋으로 바꾸는 과정을 뜻하며 분해 신뢰성과 정확성을 높일 수 있다.

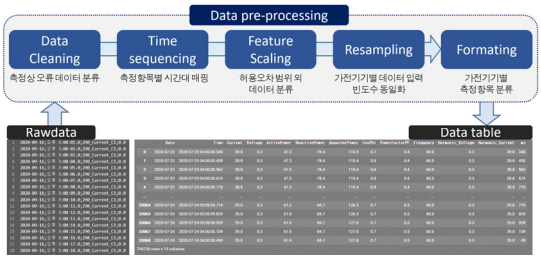

Fig. 4. Deep learning training data set pre-processing process for energy disaggregation.

Data Cleaning : 불필요한 데이터를 제거하였다. 본 연구에서 메인 전력 측정 장치로부터 취합되는 데이터는 전압, 전류, 전력량, 유효전력, 피상전력, 무효전력, 역률, 전압주파수, 전류주파수, 시간, 전압고조파, 전류고조파이다. 유효전력을 제외 하고 나머지 데이터는 제외 하였다. 또한 유효전력의 경우 현장에서의 다양한 문제로 인해 음의 값이 측정되기도 하는데 모든 음의 값의 유효전력은 0으로 처리 하였다.

Time sequencing : 모든 데이터를 시간에 맞추어 time-sequence 데이터로 맞추는 작업을 하였다. 시간 데이터와 유효전력 데이터를 1:N 매핑하는 과정을 수행하였다. 또한 LSTM 알고리즘 특성상 장기-단기 데이터를 기억할 수 있도록 데이터를 세팅해야 하는데, 본 연구에서는 60초의 데이터를 기억할 수 있도록 Time-sequencing 하였다.

Feature Scaling : 일부 데이터의 경우 ms 단위로 측정되어 10000배 이상의 데이터가 측정되는 경우가 있는데, 이는 노이즈로 간주하고 제거하였다. 또한 학습의 효율성을 높이기 위하여 모든 전력 데이터를 0~1.0으로 스케일 매핑을 수행하였다.

Resampling : LSTM 알고리즘은 단위 시간당 유효전력 데이터의 개수가 모든 가전기기에 대해서 같아야 한다. Resampling 알고리즘을 통해 데이터 입력 빈도수를 일정하게 하였다.

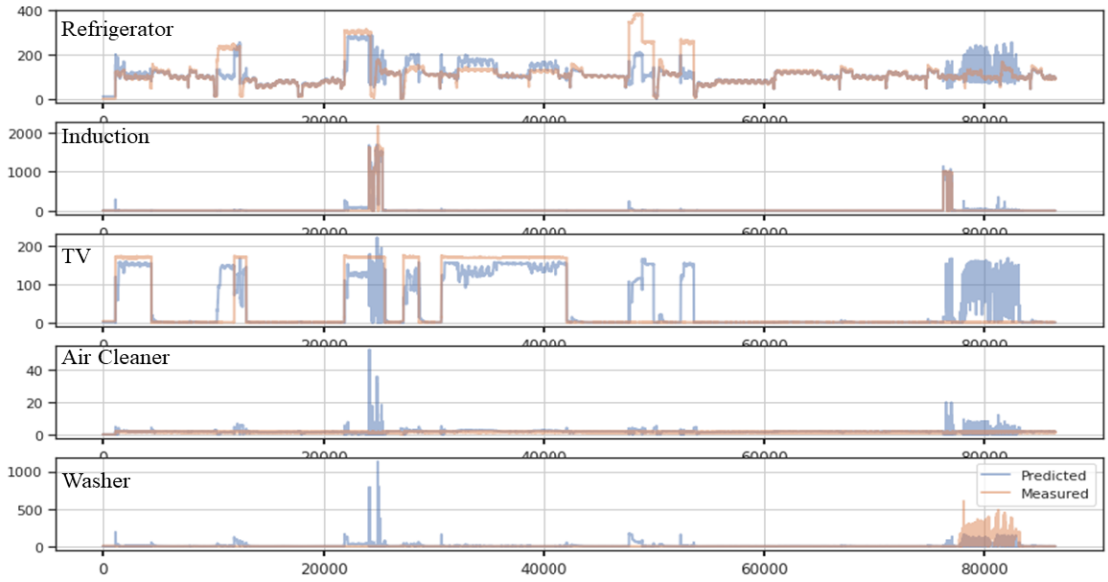

Fig. 5. Time series plot results of energy decomposition results for each home appliance

Formating : 센서로부터 측정된 데이터는 가전기기별로 따로 저장된다. 시간-메인 유효전력-가전기기별 유효전력 순서로 하나의 테이블로 정리하였다.

LSTM 신경망은 총 50개로 구성했으며 Early-stop을 위한 patience는 10으로 설정하였다. 총 학습 파라미터 개수는 10655개로 설정 되었고, 총 Epoch 100회로 설정하여 학습을 수행하였으며 Colab 환경에서 T4 GPU를 활용하였다. 또한 콜백 함수로써 Learning rate 스케줄러와 최적 모델을 자동으로 저장 하는 Check point 함수를 이용하였다. 총 학습 시간은 16시간동안 수행하였다. 최종 손실 값은 1.2222e-04 였으며, 더 이상 손실 값의 하강과 정확도 향상이 없을 것으로 판단하여 해당 신경망을 이용하여 분해를 수행하였다. Fig. 2. 의 스팩토그램 분석을 수행한 같은 기간에 대해 분해 결과는 Fig. 5. 와 같다. 5개 기기 전체에 대한 분해 정확도는 89.79%로 측정 되었다. 중앙 측정 전력 에너지의 시계열 총합의 데이터로부터 분해가 완료된 5종 가전기기의 전력 값과 실제로 측정한 전력 값의 차이에 따른 에러를 아래와 같은 식으로 정확도를 계산 하였다.

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

냉장고과 인덕션의 경우에는 꽤 유사한 수준의 분해가 이루어 졌음을 알 수 있다. 그러나 냉장고의 80000초 부근의 전력 사용량의 데이터는 다소 다른 패턴으로 인식하여 전력 사용량을 분해한 것을 확인 할 수 있다. 같은 시간대의 세탁기의 전력 사용량을 확인해보면 세탁기의 사용 패턴을 냉장고의 사용량으로 인식하여 세탁기의 사용량이 분해 성능에 악영향을 미쳤음을 알 수 있다. TV의 경우에도 사용시간을 분해하는 데는 어느정도 유사한 결과를 얻었음을 알 수 있으나 80000초 부근의 데이터에서 큰 에러를 일으켰음을 알 수 있다. 공기 청정기의 경우에는 전력 사용량이 극히 적어 On/Off 신호가 명확하지 않다는 특성과 전체적인 전력 사용량이 너무 작아 전력 사용 예측에 있어 큰 오차를 나타내었다. 세탁기의 경우에는 실제 가전기기 사용율이 적다는 특성이 있다. 실제 사용한 시간은 80000초 부근에서 한번 사용하였는데, 세탁기의 패턴을 LSTM 신경망이 명확히 학습하지 못하여 다른 가전기기에도 에러가 커지는 영향을 미친 것으로 분석 된다.

5. 결론

본 연구에서는 전기기 5종에 대해 실제 측정 전력 데이터를 이용하여 스팩토그램 분석을 통해 가전기기별 전력 특징을 분석하고, LSTM 딥러닝 기반의 시계열 데이터 학습을 통한 2단계 NILM 기법을 제안하고 그 효용성을 확인하였다. 3개월 데이터 기준 정확도 89.79% 신뢰도를 확보하였다. 실측 데이터 전처리 방법을 소개하고 Spectogram 분석을 통해 가전 기기별 특징을 추출해내 분해 성능을 향상 시켰다. 향후 연구로써 main 전력 기기의 전력 데이터만으로 신뢰도 높은 5종 전력 신호를 분해해낼 수 있는 알고리즘을 확보하기 위해 전력 분해를 위한 전처리 필터 개발, 유효전력 이외의 무효전력, 피상 전력 등의 다른 전력 데이터의 상관 관계를 학습한 분해 알고리즘 개발 등을 수행할 예정이다.

REFERENCES

[1] Eurostat. (27 March 2018). *Energy Statistics—An Overview*. Available online. https://ec.europa.eu

[2] O. Elma & U. S. Selamogullar. (2017). A survey of a residential load profile for demand side management systems. *IEEE Internatdional Conference on Smart Energy Grid Engineering (SEGE).* DOI : 10.1109/SEGE.2017.8052781

[3] S. Mostafavi & R. W. Cox. (2017). An unsupervised approach in learning load patterns for non-intrusive load monitoring. *IEEE 14th International Conference on Networking. Sensing and Control (ICNSC).* DOI : 10.1109/icnsc.2017.8000164

[4] L. Pérez-Lombard, J. Ortiz & C. Pout. (2008). A review on buildings energy consumption information. *Energy and Build. 40(3),* 394-398. DOI : 10.1016/j.enbuild.2007.03.007

[5] D. Lee & C-C. Cheng. (2016). Energy savings by energy management systems: A review. *Renewable and Sustainable Energy Reviews. 56,* 760-777. DOI :10.1016/j.rser.2015.11.067

[6] S. Katipamula & M. Brambley. (2005). Review Article: Methods for Fault Detection, Diagnostics, and Prognostics for Building Systems—A Review, Part II. *HVAC&R Reserach. 11(2),* 169-187. DOI :10.1080/10789669.2005.10391133

[7] M. Zeifman & K. Roth. (2011). Viterbi algorithm with sparse transitions (VAST) for nonintrusive load monitoring. *IEEE Symposium on Computational Intelligence Applications In Smart Grid (CIASG).* 1-8. DOI : 10.1109/CIASG.2011.5953328

[8] C. Ogwumike, M. Short & M. Denai. (2015). Near-optimal scheduling of residential smart home appliances using heuristic approach. *IEEE International Conference on Industrial Technology (ICIT).* 3128-3133.
DOI : 10.1109/ICIT.2015.7125560

[9] V. Indragandhi, R. Logesh, V. Subramaniyaswamy, V. Varadarajan, P. Siarry & L. Uden. (2018). Multi-objective optimization and energy management in renewable based AC/DC microgrid. *Computers & Electrical Engineering. 70,* 179-198.
DOI : 10.1016/j.compeleceng.2018.01.023

[10] K. Buchanan, N. Banks, I. Preston & R. Russo, (2016). The British public's perception of the UK smart metering initiative: Threats and opportunities. *Energy Policy.* 91. 87-97.
DOI : 10.1016/j.enpol.2016.01.003

[11] G. C. Koutitas & L. Tassiulas. (2016). Low cost disaggregation of smart meter sensor data. *IEEE Sensors. J. 16(6),* 1665-1673.
DOI : 10.1109/JSEN.2015.2501422

[12] G. W. Hart. (1992). Nonintrusive appliance load monitoring. *Proceedings of the IEEE. 80(12)*, 1870-1891.
DOI : 10.1109/5.192069

[13] R. Arghandeh & Y. Zhou. (2018). *Big Data Application in Power Systems,* Amsterdam : Elsevier Science.
DOI : 10.1016/c2016-0-00194-8

[14] D. Egarter, V. P. Bhuvana & W. Elmenreich. (2015). PALDi: Online Load Disaggregation via Particle Filtering. *IEEE Transactions on Instrumentation and Measurement. 64(2),* 467-477.
DOI : 10.1109/tim.2014.2344373

[15] A. Cominola, M. Giuliani, D. Piga, A. Castelletti & A. E. Rizzoli. (2017). A Hybrid Signature-based Iterative Disaggregation algorithm for Non-Intrusive Load Monitoring. *Applied Energy 185,* 331-344.
DOI : 10.1016/j.apenergy.2016.10.040

[16] C. Gisler, A. Ridi, D. Zuerey, O. A. Khaled & J. Hennebert. (2013). Appliance consumption signature database and recognition test protocols. *8th International Workshop on Systems, Signal Processing and their Applications (WoSSPA),* 336-341.
DOI : 10.1109/wosspa.2013.6602387

[17] A. S. Bouhouras, P. A. Gkaidatzis, E. Panagiotou, N. Poulakis & G. C. Christoforidis. A NILM algorithm with enhanced disaggregation scheme under harmonic current vectors. *Energy and Buildings, 183(15),* 392-407
DOI : 10.1016/j.enbuild.2018.11.013

[18] T. Hassan, F. Javed & N. Arshad. (2014). An empirical investigation of V-I trajectory based load signatures for non-intrusive load monitoring. *IEEE Transactions on Smart Grid, 5(2),* 870-878.
DOI : 10.1109/TSG.2013.2271282

[19] Y. H. Lin & M-S. Tsai. (2015). An advanced home energy management system facilitated by nonintrusive load monitoring with automated multiobjective power scheduling. *Transactions on Smart Grid, 6(4),* 1839-1851.
DOI : 10.1109/TSG.2015.2388492

[20] P. Bilski & W. Winiecki. Generalized algorithm for the non-intrusive identification of electrical appliances in the household. *IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS),* 730-735.
DOI : 10.1109/IDAACS.2017.8095186

[21] Y. Kim, S. Kong, R. Ko & S. -K. Joo. (2014). Electrical event identification technique for monitoring home appliance load using load signatures. *IEEE International Conference on Consumer Electronics (ICCE),* 296-297.
DOI : 10.1109/ICCE.2014.6776012

[22] D. Murray, L. Stankovic, V. Stankovic, S. Lulic, S. Sladojevic, (2019). Transferability of neural network approaches for low-rate energy disaggregation. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP),* 8330-8334.
DOI : 10.1109/ICASSP.2019.8682486

[23] K. S. Barsim & B. Yang. (5 Feb 2018). *On the Feasibility of Generic Deep Disaggregation for Single-Load Extraction.* New york : Cornell University https://arxiv.org/abs/1802.02139v1

[24] X. Wu, X. Han & K. X. Liang. (2019). Event-based non-intrusive load identification algorithm for residential loads combined with underdetermined decomposition and characteristic filtering. *IET Generation, Transmission & Distribution, 13(1),* 99-107.
DOI : 10.1049/iet-gtd.2018.6125

[25] ˙I. Çavdar & V. Faryad. (2019). New Design of a Supervised Energy Disaggregation Model Based on the Deep Neural Network for a Smart Grid *Energies, 12(7),* 1217.
DOI : 10.3390/en12071217

[26] W. He & Y. Chai. (2016). An empirical study on energy disaggregation via deep learning. *Proceedings of the 2016 2nd International Conference on Artificial Intelligence and Industrial Engineering (AIIE 2016).*
DOI : 10.2991/aiie-16.2016.77

[27] L. Mauch & B. Yang. (2015). A new approach for supervised power disaggregation by using a deep recurrent LSTM network. *IEEE Global Conference on Signal and Information Processing (GlobalSIP),* 63-67.
DOI : 10.1109/GlobalSIP.2015.7418157

[28] F. C. C. Garcia, C. M. C. Creayla & E. Q. B. Macabebe. (2017). Development of an intelligent system for smart home energy disaggregation using stacked denoising autoencoders. *Procedia Computer Science, 105,* 248-255.

DOI : 10.1016/j.procs.2017.01.218

[29] S. J. Cho & T. Y. Yoon. (2016). *Seasonal pattern analysis and implications for residential electricity demand.* Ulsan : KEEI. https://www.nkis.re.kr:4445/subject_view1.do?otpId=KEEI00047525&otpSeq=0&eoSeq=0

김 임 규(Imgyu Kim) [정회원]

· 2013년 2월 : 인하대학교 기계공학부 (공학사)
· 2016년 2월 : 한국과학기술원 해양시스템공학과 (공학석사)
· 2016년 3월 ~ 현재 : 한국과학기술원 기계공학과 (공학박사)
· 관심분야 : 시뮬레이션, 인공지능
· E-Mail : kimimgoo@kaist.ac.kr

김 현 철(Hyuncheol Kim) [정회원]

· 2019년 2월 : 한국과학기술원 기계공학과 (공학박사)
· 2019년 2월 ~ 현재 : i CAPTAIN Co., Ltd. 대표이사
· 관심분야 : 시뮬레이션, 인공지능
· E-Mail : ceo@icaptain.kr

김 승 윤(Seungyun Kim) [정회원]

· 2016년 2월 : 충북대학교 전자공학과 (공학사)
· 2017년 2월 ~ 2019년 8월 : ㈜팸텍 영상기술팀 알고리즘 연구원
· 2021년 2월 ~ 현재 : ㈜컨트롤클로더 AI팀 매니저
· 관심분야 : 인공지능, 주식
· E-Mail : kiricsyuunie@gmail.com

신 상 용(Sang-Yong Shin) [정회원]

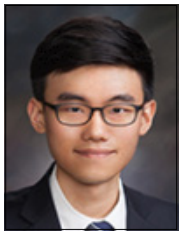

· 2015년 2월 : 충북대학교 건축공학과 (공학사)
· 2017년 8월 : 충북대학교 건축공학과 (공학석사)
· 2020년 2월 ~ 현재 : (주)바이솔라 친환경기술연구소 연구원
· 관심분야 : 건물에너지, 인공지능
· E-Mail : ssy.buysolar@gmail.com