

공동주택 전력 소비 데이터 분석 및 딥러닝을 사용한 전력 소비 예측

Analysis of Apartment Power Consumption and Forecast of Power Consumption Based on Deep Learning

유 남 조*, 이 은 애*, 정 범 진**, 김 동 식*

Namjo Yoo*, Eunae Lee*, Beom Jin Chung**, Dong Sik Kim*

Abstract

In order to increase energy efficiency, developments of the advanced metering infrastructure (AMI) in the smart grid technology have recently been actively conducted. An essential part of AMI is analyzing power consumption and forecasting consumption patterns. In this paper, we analyze the power consumption and summarized the data errors. Monthly power consumption patterns are also analyzed using the k-means clustering algorithm. Forecasting the consumption pattern by each household is difficult. Therefore, we first classify the data into 100 clusters and then predict the average of the next day as the daily average of the clusters based on the deep neural network. Using practically collected AMI data, we analyzed the data errors and could successfully conducted power forecasting based on a clustering technique.

요 약

에너지의 생산 효율성을 증가시키기 위해 최근 스마트그리드 기술 중 지능형 검침 시스템(AMI, advanced metering infrastructure)의 개발이 활발히 진행되고 있다. 전력 소비 데이터를 분석하고 소비 패턴을 예측하는 일은 AMI에서 핵심적인 부분이다. 본 논문에서는 수집된 전력 소비 데이터를 분석하고 발생할 수 있는 오류들을 정리하였으며 소비 패턴을 월별로 k-means 군집화 알고리즘을 사용하여 분석하였다. 또한 deep neural network를 이용하여 소비 패턴을 예측하였는데, 가 구별 하루 전력 사용량 예측의 어려움을 극복하기 위하여 전력 사용량을 100개의 군집으로 분류하여 이 군집의 하루 평균으로 다음날 군집의 평균을 예측하였다. 실제 AMI에서의 전력 데이터를 사용하여 오류들을 분석하였으며 군집화 방법을 도입하여 성공적으로 전력 소비 예측이 가능하였다.

Key words : advanced metering infrastructure, deep neural network, load data, load forecasting, k-means clustering, meter reading

* Dept. of Electronics Engineering, Hankuk University of Foreign Studies

** Dept. of Electrical and Information Engineering, Seoul National University of Science and Technology

★ Corresponding author

E-mail : namjo1106@hufs.ac.kr, Tel : +82-31-330-4582

※ Acknowledgment

This work was supported by the Korea Institute of Energy Technology Evaluation and Planning(KETEP) and the Ministry of Trade, Industry & Energy(MOTIE) of the Republic of Korea (No. 20191210301580).

This work was also supported by Hankuk University of Foreign Studies Research Fund of 2019.

Manuscript received, Dec. 2, 2019; revised Dec. 23, 2019; accepted Dec. 29, 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

현재의 전력 시스템은 최대 수요량을 예측하고 이에 맞춰 전력예비율을 관리하여 실제 전력수요보다 15% 정도 많이 생산하는 단방향성 전력공급으로 운영되고 있다. 최근 지속가능한 사회를 위해서 화석연료를 감축하고 신재생에너지의 발전을 증가시키는 에너지전환정책의 발표로 인하여 정확하고 신속한 수요 예측의 필요성이 대두되고 있다. 그로 인해 전력시스템의 효율성을 증가시키는 전력망과 정보통신기술을 융합한 스마트그리드 기술이 개발되고 있다. 스마트그리드란 전력공급자와 소비자가 실시간 사용 정보를 교환하여 에너지 사용량 예측과 생산의 운용으로 에너지 효율을 최대화하는 차세대 전력망이다. 이 기술을 통해 단방향성의 중앙집중형 계통운영에서 중앙의 전력운영시스템과 다수의 수요자원, 소규모 분산전원 등이 상호 유기적이며 복합적으로 거래 및 운영되는 실시간 양방향성의 계통운영으로 전환된다. 스마트그리드 기술 중 핵심적인 기술로 최근에 주목받는 것이 지능형 검침 시스템(AMI, advanced metering infrastructure)이다[1]. AMI는 기존의 월 단위 인력 검침 방식을 양방향 통신 기능을 추가하여 15분, 한 시간 단위의 실시간 원격 검침이 가능하도록 구성한 것으로 원격검침기능 외에 전력회사의 계량기 및 배전설비 관리, 수집된 계량정보를 기반으로 한 소비자 맞춤형 전력정보 제공, 소비자의 수요 감축을 포함한 수요반응(DR, demand response) 등 스마트그리드 환경에서 요구하는 다수의 이해

관계자간의 실시간 전력정보 수집 및 공유를 위한 정보체계이다[2]. 그림 1은 AMI 시스템을 도시화한 것이다[3].

AMI 기술개발은 크게 지능형 전력량계(smart meter), AMI 현장망(field area network), 미터데이터관리시스템(MDMS, meter data management system)의 영역이 있다. 이 중 지능형 전력량계의 주요 기능은 시간대별 요금제(TOU, time of use), 선택형 요금제의 수용, 소비자의 전력 정보(LP, load profile) 수집, 순 계량(net-metering) 수용, 정전 및 복전 알림, 도전 감지이다. 여기서 전력 소비 데이터를 수집하여 사용패턴을 분석하는 과정은 데이터의 분석이 필수적으로 수행되어야 한다[4].

하지만 수집된 데이터에는 여러 요인으로 오류가 발생할 수 있으므로 전력사업자는 다양한 보정방법을 통해서 수집된 전력소비 데이터의 유효성을 검증해야 하며 이를 위해 다양한 방법이 존재한다[5]. 데이터 분석과 소비자의 전력 소비 패턴을 파악하여 향후 전력 소비를 예측하는 것은 전력을 효율적으로 관리하기 위해 필수적이다[6]. 기존 연구에서도 전력 소비를 예측하기 위해 회귀분석과 딥러닝을 이용한 방법들이 있으며 다양한 모델을 이용하여 예측의 정확도를 개선하고 있다[7].

전력회사는 AMI에서 요구하는 통신품질 및 계량품질을 확보하기 위하여 많은 노력을 하고 있으나 고압수전 아파트와 같은 공동주택의 경우 아파트 단지 내 세대용 전력량계는 계량정밀도 및 통신의 품질, 검침프로토콜의 비표준성 등으로 인하여 양질의 전력 소비 데이터를 획득하기 어렵다. 이러한 문제점은 전력 소비 패턴을 정확히 예측하지 못하는 원인이 된다. 딥러닝 기법에서 데이터의 개수가 부족하면 모델을 정확히 학습할 수 없으며 소비 패턴 예측도 정확하게 할 수 없기 때문에 데이터의 개수는 딥러닝 모델을 이용하여 전력 소비 패턴을 예측할 때 중요한 부분이다[8].

본 논문에서는 원격검침이 구축된 공동주택에서 수집된 공동주택 전력 소비 데이터를 분석하여 수집과정에서 발생할 수 있는 오류들을 정의하고 보정방법에 대해 서술한다. 또한 아홉 달(1월~9월)의 한 시간 단위 전력 사용 데이터를 분석하고 k-means 알고리즘을 사용하여 군집화 작업을 하여 전력 소비 패턴을 분석하고 DNN(deep neural network)를 사용하여 전력 소비 패턴을 예측한다. 이때 제한적

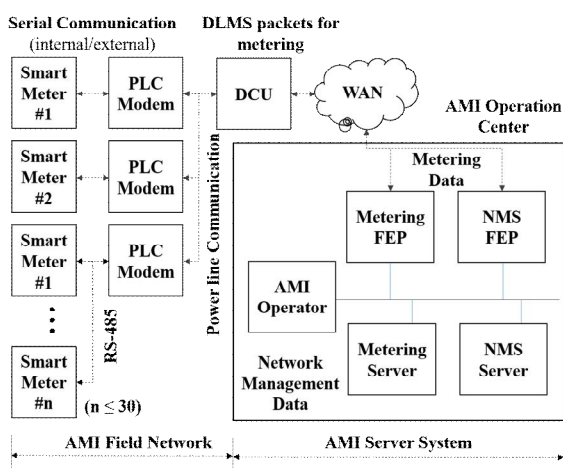


Fig. 1. Example of a structure of the AMI system.

그림 1. AMI 시스템 구성의 예

인 데이터를 가지고 예측의 정확도를 개선하기 위해서 데이터를 군집화하여 분류하였으며, 딥러닝 모델을 학습하기 위한 데이터의 개수를 증가시켜 효율성을 높이고 모델의 정확도를 높이는 방법을 제안하였다[9].

본 논문의 구성은 다음과 같다. 제 2장은 공동주택의 원격검침 시스템에서 수집된 전력 소비 데이터에서 나타날 수 있는 오류분류 체계를 제시하고 보정방법에 대해 설명한다. 제 3장은 보정된 전력 소비 데이터의 1월부터 9월까지 소비 패턴을 다양한 방법으로 분석하고 k-means 알고리즘을 사용하여 군집화하고 전력 소비 패턴을 비교 및 분석한다. 제 4장에서는 DNN을 사용하여 소비자들의 전력 소비 패턴을 예측하는 방법을 고찰한다. 제 5장에는 실험 결과를 정리하고 마지막 장에서는 논문의 결론을 정리하였다.

II. 전력 소비 데이터 분석

본 장에서는 AMI 기술개발 중 지능형 전력량계를 통해 수집된 소비자들의 전력 소비 데이터를 분석하고 발생할 수 있는 오류들을 정의하여 보정 방법에 대해 고찰한다. 발생한 데이터 오류를 보정할 수 있는 방법은 다양하게 존재하는데 본 논문에서 데이터 오류의 보정은 딥러닝 과정에서 훈련 데이터를 만드는 것을 목적으로 보정을 하였다.

수집된 데이터에는 날짜, 시간, 동, 호수, 적산량, 사용량에 대한 정보가 포함된다. 시간별 전력 소비 데이터에서 발생할 수 있는 오류는 다음과 같은 다섯 가지 경우가 있다.

1. 중복된 데이터 오류

중복된 데이터 오류는 수집된 시간별 전력 소비 데이터에서 임의의 시간의 데이터가 중복으로 전송되는 경우를 의미한다. 이 오류는 수신기에서 데이터를 받고 ack 신호를 보냈으나 송신기에서 ack 신호를 받지 못하여 재전송하는 경우에 발생한다. 이때 적산량, 사용량 역시 일치하는 값이 전송되기 때문에 하나의 데이터를 제거해줌으로써 보정할 수 있다. 본 논문에 사용된 전력 소비 데이터에서 한 달 동안 발생한 duplicate data error는 약 1.90% 정도로 발생한다.

2. 다중의 누락된 데이터 오류

다중의 누락된 데이터 오류는 수집된 시간별 전력 소비 데이터에서 통신의 단절로 인하여 여러 개의 시간 데이터가 동시에 누락되는 경우를 의미한다. $x(t)$ 는 시간 t 에서 사용한 전력량을 나타내고 N 은 누락된 데이터의 개수라고 가정하자. 이때 보정을 위해 누락된 시간들의 전달과 다음날 사용 비율을 평균하여 구한다. 이를 $p(t)$ 라고 하며 수식은 다음과 같다.

$$p(t) = \frac{1}{2} \left[\frac{x(t-24)}{\sum_{i=0}^N x(t-24+i)} + \frac{x(t+24)}{\sum_{i=0}^N x(t+24+i)} \right] \quad (1)$$

비율을 구하는 과정에서 $t=0,1,\dots,N$ 시간 일 때를 사용하였다. $0 \leq t \leq N-1$ 일 때는 누락된 시간을 의미하며 $t=N$ 일 때, $x(t)$ 는 해당 시간에 사용한 전력량과 누락된 시간동안 사용한 전력량의 합에 해당하는 값을 가진다. 따라서 누적된 사용량을 비율에 따라 배분하여 보정할 수 있고 수식은 다음과 같다.

$$x'(t) = p(t) \times x(N), \quad t = 0, 1, \dots, 23 \quad (2)$$

식 2에서의 $x'(t)$ 는 보정된 전력 사용량을 의미하며, $p(t)$ 는 식 1에서 구한 시간 t 에 대한 전달, 다음날 사용 비율의 평균이다. 본 논문에서 사용된 전력 소비 데이터에서 한 달 동안 발생하는 비율은 약 0.29%이다.

3. 하나의 누락된 데이터 오류

하나의 누락된 데이터 오류는 수집된 시간별 전력 소비 데이터에서 통신의 단절로 인해서 수신되지 못한 임의의 시간의 데이터 하나가 누락되는 경우를 의미한다. 오류를 보정하기 위해서는 이전 데이터와 이후 데이터의 평균으로 보정할 수 있다.

$$x(t) = \frac{1}{2} [x(t-1) + x(t+1)], \quad x=0,1,\dots,23 \quad (3)$$

식 3에서의 $x(t)$ 는 누락된 데이터의 값이고, t 는 시 단위 시간을 의미한다. 본 논문에서 사용된 전력 소비 데이터에서 한 달 동안 발생하는 비율은 약 0.13%이다.

4. 정보 데이터 오류

정보 데이터 오류는 수집된 시간별 전력 소비 데이터에서 공동주택에 대한 정보 오류를 의미한다. 데이터를 송수신할 때 발생하는 것이 아닌 데이터를 서버에서 정리하면서 발생한다. 발생하는 오류는 날짜, 호수 정보가 정상적이지 못한 상태이다. 본 논문에서 사용된 전력 소비 데이터에서 한 달 동안 발생하는 비율은 약 0.1ppm으로 낮은 확률을 가진다.

5. 지능형 전력량계 데이터 오류

지능형 전력량계 데이터 오류는 수집된 시간별 전력 소비 데이터에서 공동주택에 설치되어있는 지능형 전력량계의 오류로 인해 적산량 오류를 의미한다. 외부적 요인과 내부적 요인으로 발생할 수 있으며 해당 시간 오류 발생 이후에는 정상적인 상태가 된다. 본 논문에서 사용된 전력 소비 데이터에서 한 달 동안 발생하는 비율은 약 0.01ppm 이하로 무시할 정도가 된다.

III. 전력 소비 패턴 분석

본 장에서는 앞 장에서 서술한 오류들을 보정하고 1월부터 9월까지 소비 패턴을 분석한 뒤 k-means 알고리즘을 이용하여 월별로 가구마다 사용 패턴을 분석하는 방법에 대해 서술한다. 사용한 전력 소비 데이터는 주중 데이터만을 사용하였다.

본 논문에서는 한 달 동안 각 가구의 평균 사용량을 구하고 k-means 알고리즘을 사용하여 총 6개의 군집으로 분류하였다[10]. 다음과 같은 방법으로 1월부터 9월까지 전력 소비 데이터를 분류하여 가구들의 소비 패턴을 월별로 비교 분석한다.

1. 전력 소비 패턴의 평균

수집된 전력 소비 데이터는 1월부터 9월까지 총 2700세대의 전력 사용량이다. 월별로 평균 사용량을 비교하기 위해 한 달 동안 각 가구의 전력 사용량을 평균하였으며 월별로 공동주택 전체 소비 패턴을 비교 분석한다.

2. K-means 군집화

K-means 알고리즘은 군집화 방법 중 분할법에 속하는 방법이다[11]. 여기서 분할법이란 주어진 데

이터를 여러 군집으로 나누는 방법이다. 각 군집은 하나의 중심을 가지며 군집에 속한 데이터들의 평균을 의미한다. 각 데이터는 중심과 유클리드 거리를 계산하여 가장 가까운 군집으로 할당된다. 이렇게 같은 중심에 할당된 데이터들이 하나의 군집을 형성하게 된다[12].

IV. 딥러닝을 이용한 전력 소비 패턴 예측

본 장에서는 전력 소비 패턴 예측을 딥러닝 모델로 예측하는 방법을 제안한다[13].

전력 소비 데이터를 가지고 소비 패턴을 예측하는 것은 효율적인 에너지 관리를 위해 필수적이다. 하지만 공급자의 입장에서 공동주택에서 각 가구별로 예측하는 것은 비효율적이다. 현재의 전력 시스템에서 공급자는 공동주택에서 각 가구에 전기를 공급하는 것이 아니라 전체 사용량에 대해서 공급하기 때문에 가구별로 예측하는 것은 의미가 없




Fig. 2. Daily power usage of a household: (a) yesterday, (b) today.

그림 2. 한 가구의 하루 전력 사용량: (a) 어제 (b) 오늘

으며 실제로 하루 사용량을 예측하는 것은 제한적이다. 그림 2의 (a)는 임의의 한 가구의 하루 전력 사용량을 나타낸 것이며 그림 2의 (b)는 다음날 전력 사용량을 나타낸다. 그림과 같이 한 가구의 하루 사용량이 너무 랜덤하기 때문에 다음날을 예측하는 것이 제한된다. 따라서 공동주택의 전체 전력 소비량의 평균을 예측하는 것이 효율적이다. 하지만 본 연구에서는 하루 단위 모든 가구의 전력 사용량을 평균하여 예측하기에는 데이터의 개수가 너무 부족하여 딥러닝을 이용하여 예측하기에는 제한적이어서 다른 방법을 제시한다.

본 논문에서는 딥러닝을 이용한 전력 소비 패턴 예측의 성능을 높이기 위해 각 가구의 하루 전력 사용량을 예측하는 것이 아닌 k-means 군집화 알고리즘을 사용하여 가구들을 분류하고 군집에 속한 가구들의 하루 전력 사용량을 평균하여 다음날 전력 사용량의 평균을 예측한다. 분류한 군집의 개수는 총 100개로 나누었으며 각 가구의 한 달 동안 전력 사용량의 평균을 분류하였고 주말을 제외한 주중 데이터만 사용하였다. 설계한 딥러닝 모델은 DNN을 사용하였으며 모델의 구성은 그림 3과 같다[14].

여기서 입력층은 분류된 군집의 하루 시간별 전력 사용량의 평균과 하루 시간별 온도를 입력으로 한다. 총 두 개의 히든 레이어를 지나 다음 날 분류된 군집의 하루 시간별 전력 사용량의 평균을 출력으로 하여 예측한다. 모델을 훈련하기 위해 사용된 데이터는 1월부터 9월의 전력 소비 데이터를 사용하였으며 검증을 위한 데이터는 각 월의 마지막 날을 사용하였다. 또한 딥러닝 모델을 사용하여 전력 소비 패턴을 예측하고 정확도 평가를 위해서 본 논문에서는 평균절대비율오차(MAPE, mean absolute

percentage error)를 구하였다.

$$MAPE = \frac{\sum_{t=1}^{24} \frac{|y'(t) - y(t)|}{y(t)}}{24} \times 100 (\%) \tag{4}$$

식 4에서의 $y'(t)$ 은 예측한 시간별 전력 소비량을 의미하고 $y(t)$ 는 실제 시간별 전력 소비량을 나타낸다.

V. 실험 결과

본 장에서는 공동주택 전력 소비 패턴을 분석하고 제안하는 방법인 군집화를 이용한 전력 소비 패턴 예측의 결과를 고찰한다.

본 논문에서 사용한 데이터는 공동주택 1월부터 9월까지 총 2700세대의 시간별 전력 소비 데이터이며 개인정보 비식별 데이터로 학술적 연구에만 사용하는 데이터이다.




Fig. 4. Monthly average power consumption with respect to time.

그림 4. 월 간 평균 전력 사용량

그림 4는 월별로 모든 가구의 전력 사용량을 평균한 것을 나타낸 것이며 그림 5는 월별 평균 기온을 나타낸다. 1월부터 9월까지 전력 사용량의 평균을 확인해 보면 7월 평균 전력 소비 데이터는 1월부터 6월, 9월의 평균 전력 소비 데이터보다 사용량이 많음을 알 수 있고 가장 많은 사용량을 가지는 월은 8월임을 알 수 있다. 특히 오후 시간대인 12시부터 15시까지의 전력 소비량은 8월이 가장 많다. 전체적으로 전력 소비 패턴은 비슷한 경향을 보이고 사용량의 차이가 존재하며 평균 온도가 높은 월에 사용량이 많다.




Fig. 3. Designed DNN model.

그림 3. 설계한 DNN 모델




Fig. 5. Monthly average temperature.
그림 5. 월 간 평균 기온

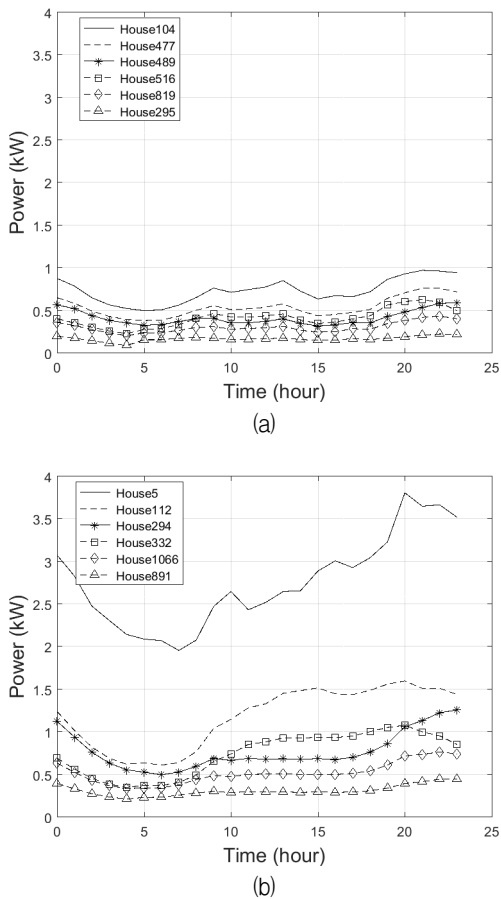


Fig. 6. Clusters of average power consumption for different households: (a) February, (b) August.
그림 6. 가구별 전력 평균 사용량 군집화: (a) 2월, (b) 8월

앞 장에서 서술한 k-means 군집화 알고리즘을 사용하여 한 달 동안 모든 가구의 전력 사용량을 분석해보면 대부분 가구들의 소비 패턴은 비슷한 경향을 보이지만 사용량의 차이가 있음을 확인할 수 있다. 그림 6은 2월과 8월의 가구별 전력 소비 사용량의 평균을 k-means 군집화 알고리즘을 이

용하여 분류하고 각 군집의 중심 값을 나타낸다. 범례는 각 군집의 해당하는 가구 수를 의미한다. 전력 소비 패턴은 비슷한 경향을 보이고 사용량의 차이가 있고 (b)가 (a)보다 전반적으로 전력사용량이 더 많음을 알 수 있다.

그림 7부터 그림 9는 딥러닝을 이용하여 다음 날 전력 소비 패턴을 예측한 결과이다. 각 그림의 (a)는 훈련된 모델에 입력한 전력 소비 패턴이며 (b)는 모델에서 출력한 전력 소비 패턴이다. 각 그림에서 예측한 전력 소비 패턴과 실제 전력 소비 패턴사이의 MAPE는 각각 3.67%, 4.08%, 4.09%를 가진다. 각 그림 (b)를 보면 예측한 전력 소비 패턴과 실제 전력 소비 패턴을 그래프에 동시에 나타내었으며 패턴 예측을 정확히 하고 있음을 알 수 있다.

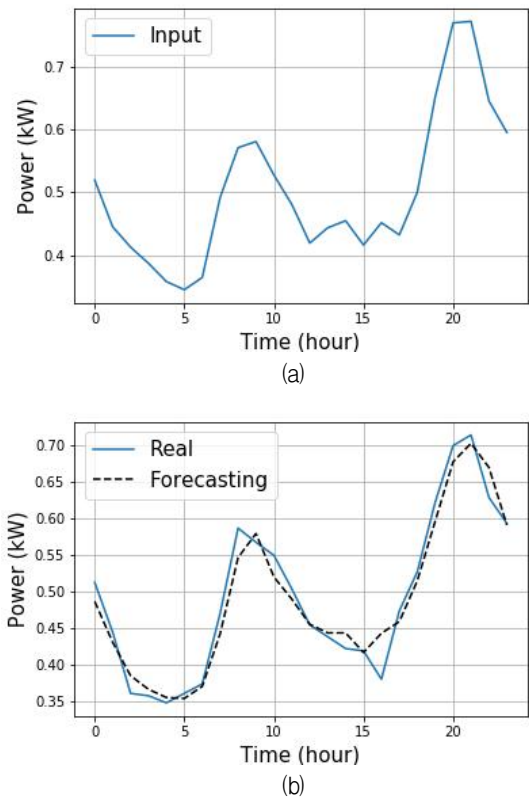


Fig. 7. Example of a prediction result for time (Example 1):
(a) Input: consumption pattern of the previous day.
(b) Output: consumption patterns of the next day and its forecasting.
그림 7. 소비 패턴 예측 결과 1 (a) 입력: 전날 소비 패턴 (b) 출력: 다음날 소비 패턴과 예측(MAPE= 3.67%)

1월부터 9월까지 공동주택 전력 사용량 데이터를 분석해보면 전반적으로 전력 소비 패턴은 유사하지만 사용량에 차이가 있음을 확인하였다. 또한 전

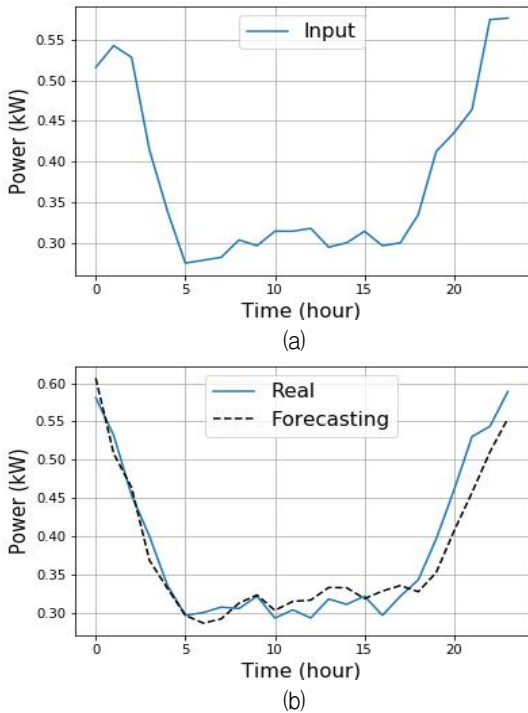


Fig. 8. Example of a prediction result for time (Example 2):
 (a) Input: consumption pattern of the previous day.
 (b) Output: consumption patterns of the next day and its forecasting.
 그림 8. 소비 패턴 예측 결과 2 (a) 입력: 전날 소비 패턴
 (b) 출력: 다음날 소비 패턴과 예측(MAPE= 4.08%)

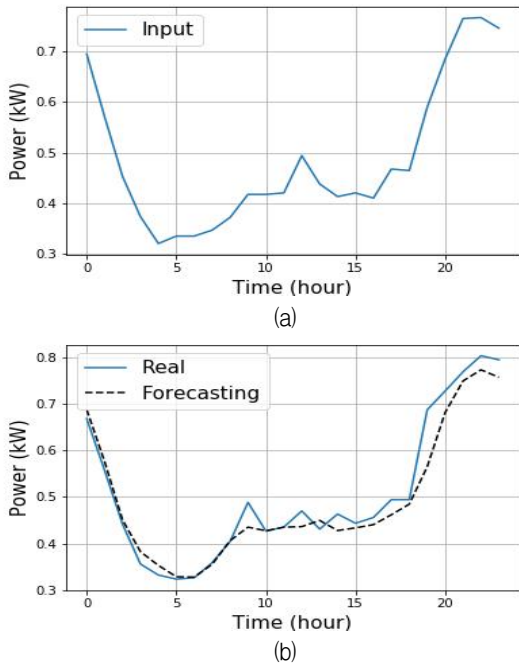


Fig. 9. Example of a prediction result for time (Example 3):
 (a) Input: consumption pattern of the previous day.
 (b) Output: consumption patterns of the next day and its forecasting.
 그림 9. 소비 패턴 예측 결과 3 (a) 입력: 전날 소비 패턴
 (b) 출력: 다음날 소비 패턴과 예측(MAPE= 4.09%)

력 사용량은 온도에 영향을 받음을 확인하였다. k-means 군집화 알고리즘을 사용하여 월별로 공동주택에 전력 소비 패턴을 분석하였으며 딥러닝을 이용하여 전력 소비 패턴을 예측하였다.

정량적, 정성적으로 예측 소비 패턴과 실제 소비 패턴을 비교 분석해 보면 정확하게 예측됨을 확인하였다.

VI. 결론

본 논문에서는 공동주택의 원격검침 시스템에서 수집된 한 시간 단위 전력 소비 데이터를 분석하였고 발생할 수 있는 오류들을 정의하고 보정하는 방법에 대해서 연구하였다. 공동주택에서 전력 소비 패턴을 월별로 평균 및 k-means 군집화 알고리즘을 사용하여 분석하였으며 전력 소비 패턴을 100개의 군집으로 분류하고 군집의 평균으로 다음 날의 전력소비 패턴을 DNN으로 예측하는 방법을 제안하였다. 제안한 다음 날의 전력 소비 예측 결과에 대해서는 정량적, 정성적으로 예측하여 성능이 우수함을 확인하였다.

References

[1] N. G. Myoung, Y. H. Kim and S. Y. Lee, "A study on AMI system of KEPCO," *The Journal of Korean Institute of Communications and Information Sciences*, Vol.35, No.8, pp.1251-1258, 2010. DOI: 10.1109/ictc.2010.5674795

[2] J. Jung and C. Seo, "An efficient method for meter data collection in AMI system," *The Journal of Korean Institute of Communications and Information Sciences*, Vol.43, No.8, pp.1311-1320, 2018. DOI: 10.7840/kics.2018.43.8.1311

[3] D. S. Kim, B. J. Chung and Y. M. Chung, "Statistical learning for service quality estimation in broadband PLC AMI," *Energies*, Vol.12, No.4, 2019. DOI: 10.3390/en12040684

[4] S. M. Jeong and H. Lee, "A consideration on the value evaluation of AMI data as big data," *Proc. KIEE Summer Conf.*, pp.45-46, 2014.

[5] Y. I. Kim, H. J. Kim, A. K. Bae, B. S. Kim and Y. H. Shin, "Apparatus and method for data

processing of energy management system,” *Proc. KIEE Summer Conf.*, pp.192-193, 2014.

[6] J. H. Chow, F. F. Wu, J. J. Momoh, “Applied Mathematics for Restructured Electric Power Systems: Optimization, Control and Computational Intelligence,” *Power Electronics and Power Systems*, Springer, pp.269-285, 2005.
DOI: 10.1007/0-387-23471-3_1

[7] A. Goia, C. May and G. Fusai, “Functional clustering and linear regression for peak load forecasting,” *International Journal of Forecasting*, Vol.26. pp.700-711, 2010.
DOI: 10.1016/j.ijforecast.2009.05.015

[8] N. Amral, C. S. Ozveren and D. King, “Short term load forecasting using multiple linear regression,” *IEEE Trans. UPEC*, Vol.42, pp. 1192-1198, 2007. DOI: 10.1109/upec.2007.4469121

[9] T. Hossen, S. J. Plathottam, R. K. Angamuthu, P. Ranganathan and H. Salehfar, “Short-term load forecasting using deep neural networks (DNN),” *IEEE Trans. NAPS*, Vol.1, pp.1-6, 2017.
DOI: 10.1109/naps.2017.8107271

[10] B. A. Smith, P. Gas, J. Wong and R. Rajagopal, “A simple way to use interval data to segment residential customers for energy efficiency and demand response program targeting,” *ACEEE Proc.*, Vol.5, pp.374-386, 2012.

[11] H. H. Bock, “Clustering methods: a history of k-means algorithms,” *Selected Contributions in Data Analysis and Classification*, pp.161-172, 2007. DOI: 10.1007/978-3-540-73560-1_15

[12] A. Likas, N. Vlassis and J. J. Verbeek, “The global k-means clustering algorithm,” *Pattern Recognition*, Vol.36, pp.451-461, 2003.
DOI: 10.1016/s0031-3203(02)00060-2


[13] D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas and M. J. Damborg, “Electric load forecasting using an artificial neural network,” *IEEE Trans. on Power Systems*, Vol.6, No.2, pp.442-449, 1991. DOI: 10.1109/59.76685

[14] T. W. S. Chow and C. T. Leung, “Neural network based short-term load forecasting using weather compensation,” *IEEE Trans on Power*

Systems, Vol.11, No.4, pp.1736-1742, 1996.
DOI: 0.1109/59.544636

BIOGRAPHY

Namjo Yoo (Member)



2018 : B.S. degree in Electronics Engineering at Hankuk University of Foreign Studies.
2018~Present : Pursuing M.S. degree in Electronics Engineering at Hankuk University of Foreign Studies.

Eunae Lee (Member)



2014 : B.S. degree in Electronics Engineering at Hankuk University of Foreign Studies.
2017 : M.S. degree in Electronics Engineering at Hankuk University of Foreign Studies.
2017~Present : Pursuing Ph.D. degree in Electronics Engineering at Hankuk University of Foreign Studies.

Beomjin Chung (Member)



1982 : B.S. degree in Electronics Engineering at Seoul National University.
1986 : M.S. degree in Electronics Engineering at Seoul National University.
2014 : Ph.D. in Electronics Engineering at Hankuk University of Foreign Studies.

Dongsik Kim (Member)



1986 : B.S. degree in Electronics Engineering at Seoul National University.
1988 : M.S. degree in Electronics Engineering at Seoul National University.
1994 : Ph.D. degree in Electronics Engineering at Seoul National University.
2000 ~ Present : Professor in Electronics Engineering at Hankuk University of Foreign Studies.