

에너지 인터넷을 위한 GRU기반 전력사용량 예측 Prediction of Power Consumptions Based on Gated Recurrent Unit for Internet of Energy

이 동 구*, 선 영 규*, 심 이 삭*, 황 유 민*, 김 수 환**, 김 진 영*

Dong-gu Lee*, Young-Ghyu Sun*, Is-sac Sim*, Yu-Min Hwang*,
Soo-hwan Kim**, Jin-Young Kim*

Abstract

Recently, accurate prediction of power consumption based on machine learning techniques in Internet of Energy (IoE) has been actively studied using the large amount of electricity data acquired from advanced metering infrastructure (AMI). In this paper, we propose a deep learning model based on Gated Recurrent Unit (GRU) as an artificial intelligence (AI) network that can effectively perform pattern recognition of time series data such as the power consumption, and analyze performance of the prediction based on real household power usage data. In the performance analysis, performance comparison between the proposed GRU-based learning model and the conventional learning model of Long Short Term Memory (LSTM) is described. In the simulation results, mean squared error (MSE), mean absolute error (MAE), forecast skill score, normalized root mean square error (RMSE), and normalized mean bias error (NMBE) are used as performance evaluation indexes, and we confirm that the performance of the prediction of the proposed GRU-based learning model is greatly improved.

요 약

최근 에너지 인터넷에서 지능형 원격검침 인프라를 이용하여 확보된 대량의 전력사용데이터를 기반으로 효과적인 전력수요 예측을 위해 다양한 기계학습기법에 관한 연구가 활발히 진행되고 있다. 본 연구에서는 전력량 데이터와 같은 시계열 데이터에 대해 효율적으로 패턴인식을 수행하는 인공지능 네트워크인 Gated Recurrent Unit(GRU)을 기반으로 딥 러닝 모델을 제안하고, 실제 가정의 전력사용량 데이터를 토대로 예측 성능을 분석한다. 제안한 학습 모델의 예측 성능과 기존의 Long Short Term Memory (LSTM) 인공지능 네트워크 기반의 전력량 예측 성능을 비교하며, 성능평가 지표로써 Mean Squared Error (MSE), Mean Absolute Error (MAE), Forecast Skill Score, Normalized Root Mean Squared Error (RMSE), Normalized Mean Bias Error (NMBE)를 이용한다. 실험 결과에서 GRU기반의 제안한 시계열 데이터 예측 모델의 전력량 수요 예측 성능이 개선되는 것을 확인한다.

Key words : Machine Learning, Deep Learning, RNN, GRU, Demand Forecasting

* Dept. of Electronic Convergence Engineering, Kwangwoon University

** Co. Gridwiz

★ Corresponding author

E-mail : jinyoung@kw.ac.kr, Tel : +82-2-940-5567

※ Acknowledgment

This work was supported by “Human Resources Program in Energy Technology” of the Korea Institute of Energy Technology Evaluation and Planning(KETEP), granted financial resource from the Ministry of Trade, Industry & Energy, Republic of Korea. (No. 20174010201620)

Manuscript received Mar. 13, 2019; revised Mar. 16, 2019; accepted Mar. 19, 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

인공지능 기술의 도입은 여러 분야에서 좋은 성능을 보여주고 있고, 활발한 연구가 진행되고 있다. 전력수요 예측분야에서도 인공지능의 한 분야인 기계학습을 도입한 연구들이 많이 진행되었다[1-3].

[1]의 연구에서는 과거의 수요 데이터, 날씨정보, 날씨정보의 특징을 추출하여 학습데이터화 시키고, 이를 순환신경망의 한 종류인 Long Short Term Memory(LSTM) 네트워크 학습에 이용했다. 그리고 학습된 모델을 통해 전력수요를 예측해 성능평가를 진행하였다. 또한, [2]의 연구에서는 LSTM 네트워크를 병렬적으로 배치해 학습을 진행하고, 각각 학습된 모델에서 나온 출력의 선형조합을 구해보고 이것의 평균을 최종 출력 결과로 도출한다. 선형조합에 필요한 각 네트워크에 대한 가중치를 선정하는 과정도 추가되며, 최종적으로 예측결과를 도출해 성능평가를 진행했다. [3]의 논문에서는 Convolutional Neural Network(CNN) 기법을 도입한다. 과거 전력수요 데이터의 특징을 CNN을 통해 추출하여 순환신경망의 학습에 이용한다. 그리고 다른 한편에서는 기온, 공휴일유무, 시간, 요일 데이터가 조합되어 CNN에 의해 추출된 특징과 통합된다. 최종적으로 통합된 출력은 예측결과를 내는 네트워크의 입력으로 들어가 학습을 진행하고, 출력을 형성한다.

본 논문에서는 순환신경망의 한 종류인 GRU를 알아보고, 이를 이용해 가정에서 측정된 전력 소비 데이터를 학습한다. 학습된 모델의 성능평가는 같은 데이터를 이용했지만 LSTM을 이용한 출력 데이터와의 비교를 통해 성능평가를 진행한다.

본 논문의 구성은 다음과 같다. 2장에서는 딥러닝 알고리즘으로써 순환신경망과 그 순환신경망의 한 종류인 GRU를 알아본다. 이어지는 3장에서는 본 연구에서 이용한 이동평균법을 통한 데이터 전처리에 대해 알아보고, 실험 데이터와 파라미터에 대해 알아본다. 또한, 실험을 통해 나온 실험결과를 분석하고 성능평가를 진행한다. 마지막으로 4장에서는 논문의 내용을 정리하고 진행 가능한 추후 연구에 대해 제시하며 본 논문을 마무리 짓는다.

II. 딥 러닝 네트워크

딥 러닝 네트워크의 가장 작은 구성요소는 인공

뉴런이다. 인공뉴런은 용어 그대로 인간의 뉴런을 인공적으로 모델링한 것을 말한다. 이 뉴런들이 모여 계층을 이루고, 이 계층은 다시, 입력을 받는 입력층, 출력을 나타내는 출력층, 그리고 입력층과 출력층 사이에 배치되는 은닉층으로 분류된다. 이런 계층구조를 인공 신경망이라고 한다. 이러한 계층구조에서 은닉층이 두 개 이상인 네트워크를 학습시켜 이용하는 것을 딥 러닝이라고 한다[4]. 그림 1은 인공뉴런과 그것으로 이루어진 인공 신경망을 보여준다.




Fig. 1. Structure of artificial neuron and deep neural network. 그림 1. 인공뉴런과 인공신경망의 구조

1. 순환 신경망

순환 신경망이란 순환 하는 구조의 계층을 은닉층으로 이용하여 이전 시점의 은닉층 출력이 현재 시점의 은닉층으로 입력되어 은닉층 연산에 포함되는 신경망을 말한다[5]. 그림 2는 간단한 순환 신경망의 구조를 예시로 보여준다. 그림 2의 왼쪽 구조가 기본구조이고, 기본구조를 시간흐름에 따라 분석해보면 화살표 오른쪽의 그림처럼 표현된다. 그림에서 x 는 입력층, h 는 은닉층을, o 는 출력층을 나타낸다. 또한 V , W , U 는 각 연결의 연결 계수를 의미한다. 마지막으로 그림 2에 있는 아래첨자들은




Fig. 2. Structure of Recurrent Neural Network. 그림 2. 순환 신경망의 구조

시점을 나타낸다. 순환 신경망은 시계열 데이터 처리에 좋은 성능을 보여준다. 본 연구에서 사용하는 전력량 데이터도 시계열 데이터이기 때문에 순환 신경망의 한 종류인 GRU를 이용한다.

2. GRU

GRU는 [6]에서 처음 소개되었는데, LSTM과 같이 게이트의 개념을 이용한 순환 신경망의 일종이다[7, 8]. 그림 3은 GRU의 기본 구조를 보여준다. GRU는 두 개의 게이트를 이용해 입력을 연산하는데, 그 게이트의 이름은 ‘업데이트 게이트’ 그리고 ‘리셋 게이트’이다. 이제 입력이 GRU로 들어와 연산되는 과정을 서술하겠다.

먼저 업데이트 게이트의 연산을 알아보겠다. 업데이트 게이트는 이전 시점의 출력과 현재 시점의 연산결과 중 어떤 것에 더 가중치를 주는가를 결정해준다. 업데이트 게이트 G_u 는 수식적으로 다음과 같이 표현된다.

$$G_u = \sigma(W_u[C_{t-1}, x_t] + b_u). \quad (1)$$

수식 1에서 σ 는 sigmoid 활성화함수를 의미한다. W_u 는 업데이트 게이트의 연결계수, C_{t-1} 은 이전 시점의 출력값, x_t 는 현재 시점의 입력값 그리고 b_u 는 업데이트 게이트의 바이어스값을 의미한다.

그 다음 리셋게이트의 연산을 알아보자. 리셋게이트는 이전 시점의 출력값을 새로운 현재 시점의 출력이 될 출력 후보값에 얼마나 포함시킬 것인지 결정해준다. 이 현재 시점의 후보값과 리셋게이트의 연산을 수식으로 표현하면 다음과 같다.

$$\tilde{C}_t = \tanh(W_c[G_r \odot C_{t-1}, x_t] + b_c). \quad (2)$$

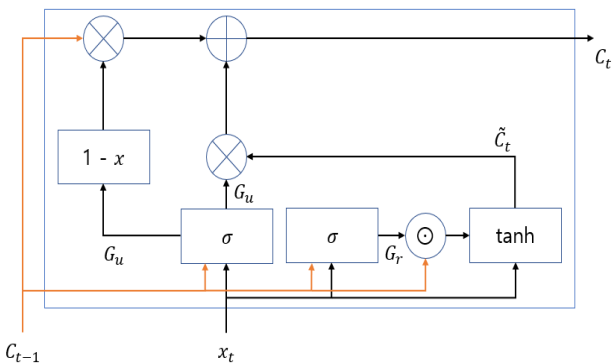


Fig. 3. Structure of GRU.

그림 3. GRU의 구조

$$G_r = \sigma(W_r[C_{t-1}, x_t] + b_r). \quad (3)$$

수식 2에서 \tilde{C}_t 는 현재 시점에서의 출력 후보값을 나타내고, W_c 와 b_c 는 각각 연결 계수와 바이어스값을 나타낸다. 그리고 G_r 은 리셋게이트 값을 나타내고 \odot 는 행렬의 성분곱 연산을 의미한다. 그리고 수식 3에서의 W_r 과 b_r 은 리셋게이트의 연결계수와 바이어스값을 나타낸다.

이제 마지막으로 연산한 결과들을 토대로 현재 시점의 출력값을 결정하는 단계가 진행된다. 그 과정을 수식으로 나타내면 다음과 같다.

$$C_t = G_u \tilde{C}_t + (1 - G_u) C_{t-1}. \quad (4)$$

수식 4는 GRU의 최종 출력을 결정하는 과정을 보여준다. 수식을 보면 업데이트 게이트 값 G_u 가 현재 시점의 출력 후보값과 이전 시점의 출력값의 반영 비율을 결정한다는 것을 알 수 있다. G_u 값은 sigmoid함수의 출력값이기 때문에 그 출력의 범위가 0에서 1로 제한되게 된다. 이때 만약 G_u 의 값이 0이라면 최종 출력에서 \tilde{C}_t 는 반영되지 않고 C_{t-1} 을 그대로 취하게 된다. 반대로 만약 G_u 의 값이 1이라면 C_{t-1} 은 현재 시점의 출력에 전혀 반영되지 않고 \tilde{C}_t 을 출력값으로 결정하게 된다. 이러한 순환 연산 과정은 입력이 모두 입력되어 연산되고 출력으로 나가는 과정이 끝날 때까지 반복된다.

III. 실험 환경 및 결과

1. 실험 데이터

본 논문에서 진행한 실험에서 사용한 데이터는 UMass Trace Respository에서 제공한 가정단위 전력사용량 데이터이다[9]. 학습에 사용한 데이터는 2016년 1월 1일부터 2016년 2월까지 두 달간의 데이터를 사용하였다. 검증 데이터는 2016년 3월 1일부터 3월 14일까지 사용하였고, 모델의 실제적인 성능평가에 이용한 테스트 데이터는 3월 15일부터 31일까지를 사용하여 실험을 진행하였다.

2. 데이터 전처리

제공된 데이터를 확인해보았을 때, 전력 사용량 패턴은 대체로 특정 경향을 띄지만 갑자기 치솟거

나 급락하는 구간이 존재한다. 본 연구에서는 이러한 급변하는 구간의 영향력을 줄이기 위해 이동평균법을 이용한 데이터 전처리 과정을 진행하였다. 이동평균법은 각 구간마다 평균값을 구해서 해당 구간의 값을 모두 그 평균으로 나누어주는 방법을 의미한다[10]. 이 방법으로 전처리를 진행하면 데이터가 급변하는 구간에서 급변하는 범위가 작아져 데이터의 변화가 완곡해지는 이점을 얻을 수 있다. 이동평균법을 통한 데이터 전처리를 수식적으로 나타내면 다음과 같이 표현된다.

$$(x'_0, x'_1, \dots, x'_m) = (x_0, x_1, \dots, x_m) \times \frac{w}{\sum_{i=a}^{a+w} x_i} \quad (5)$$

수식 5에서 x'_i 값은 데이터 전처리를 진행한 값들이고, x_i 값은 데이터 전처리 이전의 원본 데이터를 의미한다. a 는 평균을 구하는 구간의 시작지점을 나타낸다. 연산을 진행해 나가면서 a 값 또한 0부터 마지막 데이터 샘플의 인덱스 n 까지 이동해 나간다. 또한 w 값은 평균을 구하는 범위의 크기로 윈도우 사이즈라고 한다.

3. 실험 파라미터

본 연구에서 진행한 실험에서 사용한 실험 파라미터는 다음과 같다. 유닛의 개수, batch 사이즈, epoch, look_back 그리고 윈도우 사이즈로 총합 5개의 파라미터를 조정해가며 실험하였다.

첫 번째로, GRU 유닛의 개수이다. 은닉층으로 사용한 GRU 유닛이 각 계층마다 몇 개가 있는지 알 수 있는 파라미터이다. 유닛의 개수가 많다는 말은 네트워크가 더 커진다는 의미이다. 복잡한 데이터를 처리하는 네트워크일수록 더 복잡한 네트워크가 필요할 것이라고 예상된다. 본 실험에서는 이 파라미터를 실험적으로 90으로 설정하였다.

두 번째로, batch 사이즈이다. 이 파라미터는 학습이 진행되는 단위를 설정해준다. 다시 말해, 데이터 셋 몇 개를 받아 연산을 해보고 네트워크 내부의 변수들을 조정할 것인지 정해준다. 이 값은 실험적으로 15로 설정했다.

세 번째로, epoch는 반복학습 횟수를 의미한다. 모델을 학습시킬 때, 학습데이터를 여러 횟수 반복 학습 시키게 되는데 이 횟수를 정해주는 파라미터이다. 이 값은 100으로 설정했다.

네 번째로, look_back은 데이터셋의 단위를 결정해준다. 데이터셋 한 개를 얼마나 큰 크기로 구성할 것인지 결정하는 파라미터이다. 이 값은 48로 설정하였다.

마지막으로 윈도우 사이즈는 데이터의 전처리 파트에서 언급한 w 와 같은 파라미터이다. 이 값은 48로 설정하였다. 제공된 데이터는 30분에 1샘플로 구성된 데이터이다. 따라서 48샘플이라면 시간으로 볼 때 1일을 의미한다.

Table 1. Parameters of experiments.

표 1. 실험 파라미터

| Parameters | GRU | LSTM |
|------------------------|-----|------|
| look_back | 48 | 100 |
| Number of units | 90 | 350 |
| Batch size | 15 | 10 |
| Epoch | 100 | 100 |
| Window size | 48 | 48 |
| Number of hidden layer | 2 | 3 |

은닉층의 개수는 2개의 계층으로 네트워크를 설계했다. 표 1은 실험에서 사용한 파라미터를 정리한 것이다. 성능비교를 위해 같은 데이터로 학습시킨 LSTM의 파라미터 또한 표 1에 정리되어 있다.

4. 실험 결과

그림 4는 학습된 GRU 모델의 테스트 입력에 대한 예측 결과를 보여준다. 그림을 보면 테스트 입력의 경향을 따라가는 것을 확인할 수 있다. 하지만 값이 급상승하거나 급락하는 구간은 경향을 따라가지만 그 진폭을 온전히 따라가지는 못 하는 것을 확인할 수 있다. 그림 5에 나타나는 LSTM의 예측 결과와 GRU의 예측결과에 대해 성능평가를 MSE, MAE, Forecast skill score, NMSE, NMBE의 5가지 방법에 대해 진행하였다[11, 12, 13, 14]. 각 성능평가 방법을 수식으로 표현하면 다음과 같이 나타난다.

$$MSE = \frac{(p_1 - y_1)^2 + \dots + (p_k - y_k)^2}{k} \quad (6)$$

$$MAE = \frac{|p_1 - y_1| + \dots + |p_k - y_k|}{k} \quad (7)$$

$$Forecast Skill Score = 1 - \frac{Error_{sys}}{Error_{ref}} \quad (8)$$

$$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^k (p_i - y_i)^2}{k}}}{y_{avg}} \quad (9)$$

$$NMBE = \frac{\sum_{i=1}^k (p_i - y_i)}{k \cdot y_{avg}} \quad (10)$$

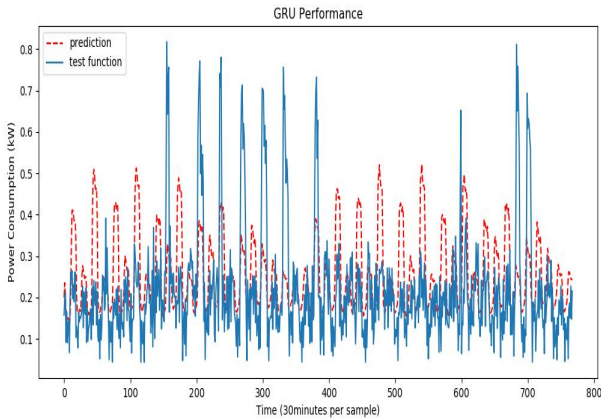


Fig. 4. Prediction result of GRU.
그림.4 GRU의 예측결과




Fig. 5. Prediction result of LSTM.
그림 5. LSTM의 예측결과

Table 2. Performance evaluation of LSTM and GRU.
표 2 LSTM과 GRU의 성능평가

| Evaluation Method | LSTM | GRU | Improvement |
|----------------------|--------|--------|-------------|
| MSE | 0.0328 | 0.0199 | 0.0129 |
| MAE | 0.1337 | 0.1036 | 0.0301 |
| Forecast Skill Score | - | 0.1688 | - |
| NRMSE | 0.8413 | 0.651 | 0.1903 |
| NMBE | 0.8073 | 0.6183 | 0.189 |

수식 6에서 10을 살펴보면, p 는 예측 결과를 의미하고 y 는 실제로 측정된 전력 값을 의미한다. k 는 샘플링 된 샘플의 개수를 나타낸다. 각 아래첨자들은 샘플번호를 말한다. 그리고 수식 8에서 $Error_{sys}$ 는 본 논문에서 제시한 GRU를 이용한 모델의 오차를 나타내고, $Error_{ref}$ 는 비교 기준이 되는 LSTM 모델의 오차를 나타낸다. Forecast skill score는 기준 모델보다 현재 시스템 모델의 성능이 더 개선되었는지 알 수 있는 지표이다. 식 9와 10에서 y_{avg} 는 실제 측정 데이터의 평균값을 의미한다. 또한 식 10에서 오차를 계산할 때 오차의 크기를 계산하기 위해 절대 값을 취해 계산했다. LSTM의 예측 결과와 본 논문에서 진행한 실험의 결과를 표 2 정리해보면 표 2와 같이 나타난다. MSE 기준으로 0.0129, MAE 기준으로 0.0301만큼의 성능개선을 확인했다. 또한 Forecast Skill Score값 0.1688을 식 8을 통해 알아보면, LSTM 오차 대비 GRU의 오차값이 약 0.83으로 나타난다. 또한 NRMSE 기준으로 0.1903의 성능개선을, NMBE 기준으로 0.189의 성능개선을 확인했다. 5가지 지표에 대해서 GRU의 실험결과는 LSTM의 실험결과보다 개선된 것을 확인할 수 있다.

III. 결론

본 연구에서는 순환 신경망의 한 종류인 GRU에 대해서 알아보았다. 그리고 이동평균법을 통해 데이터를 전처리하는 과정을 알아보았다. 다음으로, UMass Trace Repository의 전력사용량 데이터로 구성된 모델을 학습시키고, 실험을 통해 최적의 실험파라미터 5개를 설정하였다. 마지막으로 5가지 지표를 통해 성능평가를 진행하였다.

추후 진행될 수 있는 연구로는, 본 연구에서 진행한 단기 전력예측뿐만 아니라, 중기, 장기 전력 예측이 가능한 모델을 다중작업학습 기법을 이용해 학습 시키는 연구를 생각해볼 수 있다. 데이터의 특징이 유사하기 때문에 각 기간에 따른 모델을 각각 학습시키는 것 보다 하나의 모델을 학습시키는 것이 더 효과적이라고 한다. 다중작업학습 기법을 이용해 모델을 학습시키면 유사한 형태의 다양한 문제들을 미리 학습된 모델로 효과적으로 처리할 수 있을 것으로 기대된다.

References

- [1] Y. Cheng, C. Xu, D. Mashima, V. L. L. Thing and Y. Wu, "PowerLSTM: Power demand forecasting using long short-term memory neural network," in *Proc. of Advanced Data Mining and Applications: 13th International Conference*, Singapore, Singapore, pp. 727-740, 2017.
DOI: 10.1007/978-3-319-69179-4_51
- [2] J. Y. Choi and B. Lee, "Combining LSTM network ensemble via adaptive weighting for improved time series forecasting," *Mathematical Problems in Engineering*, vol. 2018, pp. 1-8, 2018. DOI: 10.1155/2018/2470171
- [3] W. He, "Load forecasting via deep neural networks," in *Proc. of 5th International Conference on Information Technology and Quantitative Management, ITQM 2017*, New Delhi, India, vol. 122, pp. 308-314, 2017.
DOI: 10.1016/j.procs.2017.11.374
- [4] S. P. Kim, *Deep Learning First Step*, Hanbit media, 2016.
- [5] I. Goodfellow, *Deep Learning*, MIT Press, 2016.
- [6] K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk and Y. Bengio, "Learning phrase representations using RNN encoder-decoder for statistical machine translation," in *Proc. of 2014 Conference on Empirical Methods in Natural Language Processing*, Doha, Qatar, pp. 1724-1734, 2014.
DOI: 10.3115/v1/D14-1179
- [7] R. Jozefowicz, W. Zaremba and I. Sutskever, "An empirical exploration of recurrent network architectures," in *Proc. of ICML'15 32nd International Conference on Machine Learning*, Lille, France, pp. 2342-2350, 2015.
- [8] J. Chung, C. Gulcehre, K. Cho and Y. Bengio, "Empirical evaluation of gated recurrent neural networks on sequence modeling," in *Proc. of NIPS 2014 Workshop on Deep Learning*, Montreal, Canada, pp. 1-9, 2014.
- [9] M. Liberatore and P. Shenoy, "UMass Trace Respository," <http://traces.cs.umass.edu/>
- [10] S. Hansun, "A new approach of moving average method in time series analysis," in *Proc. of 2013 Conference on New Media Studies (ConMedia)*, Tangerang, Indonesia, pp. 1-4, 2013.
DOI: 10.1109/CoNMedia.2013.6708545
- [11] Z. Wang and A. C. Bovik, "Mean squared error: love it or leave it? A new look at signal fidelity measures," *IEEE Signal Processing Magazine*, vol. 26, no. 1, pp. 98-117, 2009.
DOI: 10.1109/MSP.2008.930649
- [12] T. Chai and R. R. Draxler, "Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature," *Geoscientific Model Development*, vol. 7, no. 3, pp.1247-1250, 2014.
DOI: 10.5194/gmd-7-1247-2014
- [13] S. Srivastava and S. Lessmann, "A comparative study of LSTM neural networks in forecasting day-ahead global horizontal irradiance with satellite data," *Solar Energy*, vol. 162, pp. 232-247, 2018. DOI: 10.1016/j.solener.2018.01.005
- [14] B. Yildiz, J. I. Bilbao, J. Dore and A. Sproul, "Household electricity load forecasting using historical smart meter data with clustering and classification techniques," in *Proc. of 2018 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia)*, Singapore, Singapore, pp. 873-879, 2018.
DOI: 10.1109/ISGT-Asia.2018.8467837

BIOGRAPHY

Donggu Lee (Member)



2019 : B. Sc. degree in Electronic Convergence Engineering, Kwangwoon University.
2019~present : M. Sc. Course in Electronic Convergence Engineering, Kwangwoon University.

Young Ghyu Sun (Member)

2018 : B. Sc. degree in Electronic Convergence Engineering, Kwangwoon University.
2018~present : M. Sc. Course in Electronic Convergence Engineering, Kwangwoon University.

Issac Sim (Member)

2016 : B. Sc. degree in Electronic Convergence Engineering, Kwangwoon University.
2016~present : Ph. D. Course in Electronic Convergence Engineering, Kwangwoon University.

Yu Min Hwang (Member)

2012 : B. Sc. degree in Wireless Communications Engineering, Kwangwoon University.
2012~present : Ph. D. Course in Electronic Convergence Engineering, Kwangwoon University.

Soohwan Kim (Member)

2006 : M. Sc. degree in Dept. of Information Systems, Nara Institute of Science and Technology.
2011 : complete doctoral course, Dept. of Information Systems, Nara Institute of Science and Technology.

2017~ present : Co. Gridwiz, Senior Researcher

Jin Young Kim (Member)

1998 : Ph. D. degree, Dept. of Electronics Engineering, Seoul National University.
2001 : Senior Research Engineer, SK Telecom Networks Research center.

2001~ present : Professor in Dept of Electronic Convergence Engineering, Kwangwoon University.