

전력선통신 시스템을 위한 딥 러닝 기반 전력량 예측 기법

Power Consumption Prediction Scheme Based on Deep Learning for Powerline Communication Systems

이 동 구*, 김 수 현*, 정 호 철*, 선 영 규*, 심 이 삭*, 황 유 민*, 김 진 영*

Dong Gu Lee*, Soo Hyun Kim*, Ho Chul Jung*, Young Ghyu Sun*, Issac Sim*,
Yu Min Hwang*, Jin Young Kim*

Abstract

Recently, energy issues such as massive blackout due to increase in power consumption have been emerged, and it is necessary to improve the accuracy of prediction of power consumption as a solution for these problems. In this study, we investigate the difference between the actual power consumption and the predicted power consumption through the deep learning-based power consumption forecasting experiment, and the possibility of adjusting the power reserve ratio. In this paper, the prediction of the power consumption based on the deep learning can be used as a basis to reduce the power reserve ratio so as not to excessively produce extra power. The deep learning method used in this paper uses a learning model of long-short-term-memory (LSTM) structure that processes time series data. In the computer simulation, the generated power consumption data was learned, and the power consumption was predicted based on the learned model. We calculate the error between the actual and predicted power consumption amount, resulting in an error rate of 21.37%. Considering the recent power reserve ratio of 45.9%, it is possible to reduce the reserve ratio by 20% when applying the power consumption prediction algorithm proposed in this study.

요 약

최근 전력 사용량의 증가로 인한 대규모 블랙아웃 등 에너지 문제가 대두되고 있으며, 이 문제들로 인해 전력 소비량 예측에 대한 정확도를 개선할 필요성이 부각되었다. 본 연구에서는 딥 러닝 기반의 전력 사용량 예측 실험을 통해서 실제 전력 소비량과 예측된 전력 소비량의 차이를 계산하고, 이를 통해서 전력 예비율을 기존 대비 하향 조정할 수 있는 가능성에 대해서 살펴본다. 예비 전력은 사용하지 않으면 손실되는 전력으로, 본 논문에서의 딥 러닝 기반 전력 소비량 예측을 통해서 여분의 전력을 과도하게 생산하지 않도록 오차범위 내에서 전력 예비율을 감소시킬 수 있는 기반을 마련할 수 있다. 본 논문에서 사용하는 딥 러닝 기법은 시계열 데이터를 처리하는 Long-Short-Term-Memory(LSTM) 구조의 학습 모델을 이용한다. 컴퓨터 시뮬레이션에서는 임의 생성한 전력 소비 데이터를 토대로 모델을 학습시키고, 학습된 모델을 토대로 전력 사용 예측값을 구하고 실제 전력 소비량 간에 오차를 계산한 결과 오차율 21.37%를 얻을 수 있었다. 이는 최근의 전력 예비율 45.9%를 고려할 때, 본 연구에서 제안한 전력 소비량 예측 알고리즘을 적용하는 경우 20% 포인트 정도의 예비율 감축이 가능하다.

Key words : PLC, Deep Learning, RNN, LSTM, Demand Forecast

* Dept. of Wireless Communications Engineering, KwangWoon University

★ Corresponding author

E-mail : jinyoung@kw.ac.kr, Tel : +82-02-940-5567

※ Acknowledgment

This work was, in part, supported by Basic Science Research Program through the National Research Foundation of Korea funded by the Ministry of Education (NRF-2016R1D1A1B03933872)

Manuscript received Sept. 10, 2018; revised Sept. 18, 2018; accepted Sept. 19, 2018

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.

I. 서론

전력선 통신(Power Line Communication, PLC)이란 전력을 공급하는 전력선으로 데이터 통신을 하는 기술이다. 이 기술을 이용하면 전력선 자체만으로 전력사용량을 원격으로 관리 할 수 있다. 또한 이 기술을 응용해 전력선 통신을 이용한 스마트 홈 시스템도 가능하다 [1-2]. PLC는 발전과 송전, 에너지를 저장하는 Energy Storage System(ESS) 그리고 사용자가 확인 할 수 있는 어플리케이션에 이르기까지 넓은 분야를 포함하는 기술이다.

국내의 연간 전력 사용량은 97년 금융위기가 있던 해를 제외하고는 매년 증가하는 추세이다. 또한 올해는 한반도에 기록적인 폭염이 찾아와 대규모 ‘블랙아웃’ 현상도 발생하였다.

이러한 국내의 전력상황에 다양한 선행연구들이 존재한다. 시간대별 기온 데이터를 이용해 지수평활화법을 적용하는 연구가 있다. 하지만 이 방법은 계절별로 하루의 최고기온과 최저기온의 데이터만을 이용하기 때문에 시간당 변화하는 환경에 대한 전력량을 예측하기 어렵다는 단점이 있다[3-5]. 그리고 빅데이터 분석을 이용하여 과거의 기상 데이터, 전력 데이터, 웹 블로그의 키워드 검색을 분석하는 시도도 있었다 [6]. 또한 전력피크 값의 방정식을 회귀분석하고 분산분해해석을 하여 전력피크 값은 어떠한 요인에 영향을 받는지 분석한 연구도 존재한다 [7].

이러한 연구들에 대해 최근 여러 분야에서 좋은 성능을 보여주고 있는 딥 러닝 기법을 도입해 보기로 생각하였다. 다른 환경요소가 아닌 전력량 데이터를 직접 딥 러닝 모델이 학습한다면 기존의 시스템 보다 더 좋은 성능을 낼 것으로 예상했다. 딥 러닝의 깊고 복잡한 네트워크 구조로 단조로운 데이터뿐만 아니라 복잡한 패턴도 예측이 가능할 것이다. 또한 각 가정에서 이 시스템을 이용하는 시나리오를 생각해볼 때, 각 사용자의 패턴을 학습해서 사용자별로 다른 예측 결과를 낼 수 있는 장점이 있을 것으로 예상된다.

이에 본 논문은 전력량 데이터를 딥 러닝 모델에 학습시키는 딥 러닝 기반의 전력량 예측기법을 제시한다. 본 논문의 구성은 다음과 같다. 본문에서는 딥 러닝 기법과 순환신경망, 장단기메모리, 지도학습에 대해서 알아본다. 3장에서는 학습에 이용한 데이터와 학습 파라미터들을 알아보고 학습된 모델의 예측

결과를 확인해본다. 그리고 결론에서는 본 논문을 정리하고 추후에 진행될 수 있는 연구를 제안한다.

II. 딥 러닝 알고리즘

딥 러닝은 기계학습의 한 분야이다. 기계학습은 인간의 학습구조를 표현하고 컴퓨터로 구현하는 분야이다. 기계학습은 인공신경망의 형태로 표현이 가능하다. 인공신경망은 인간의 두뇌 구조를 표현하고 구현하는 통계학적 학습 알고리즘이다. 인공신경망은 뉴런, 연결계수 그리고 뉴런들의 계층구조인 레이어로 이루어진다. 레이어는 또다시 입력층, 출력층 그리고 은닉층으로 이루어진다. 이때 입력층과 출력층 사이에 두 개 이상의 은닉층이 존재하는 인공신경망을 심층신경망이라고 하고 이러한 심층신경망을 학습시키는 알고리즘을 심층학습 또는 딥 러닝이라고 한다 [8-9].

1. 순환신경망

순환신경망이란 인공신경망의 한 종류로, 시계열 데이터를 다루는데 사용되는 신경망이다. 그림 1은 순환신경망의 구조를 보여준다. 왼쪽의 구조를 시간의 흐름에 따라 펼쳐보면 화살표 오른쪽과 같은 형태로 펼쳐진다. 그림 1의 x 는 입력층, O 는 출력층, h 는 은닉층을 나타낸다. 그리고 W, U, v 는 각각 연결의 계수를 나타낸다.

순환신경망의 프로세스를 살펴보면, 먼저 입력이 시간에 따라 입력층을 통해 은닉층으로 들어간다.




Fig. 1. Structure of RNN.

그림 1. 순환신경망의 구조

이전 은닉층의 출력값이 현재의 은닉층의 입력으로 들어가게 되고, 이 두 값을 토대로 출력값을 출력해낸다. 이 과정은 입력이 모두 들어갈 때 까지 반복된다.

2. LSTM 네트워크

LSTM 네트워크는 순환신경망의 한 종류로, 은닉층을 LSTM 블록을 사용하는 네트워크를 말한다. LSTM 블록은 순환신경망의 구조처럼 이전 블록의 상태값이 현재 블록으로 들어와 연산에 관여하는 구조이다. 이 LSTM 블록은 세 단계로 나누어져 있다. 그 단계는 순서대로 망각 게이트, 입력 게이트 그리고 출력 게이트이다. 그림 2는 LSTM 블록의 구조를 보여준다. 이제 그림 2와 함께 순서대로 각 게이트의 역할에 대해 서술하겠다 [10].

첫 번째 단계는 망각 게이트이다. σ 로 표현된 레이어를 현재의 입력과 이전 입력의 은닉층 출력이 이 레이어를 통하게 된다. 이 레이어를 통해 정보를 얼마나 통과시킬 것인지 선택하게 된다. σ 는 sigmoid 활성화함수를 나타낸다. 이 함수의 수학적 표현은 다음과 같다 [11-13].

$$S(x) = \frac{1}{1 + e^{-x}}. \quad (1)$$

이 함수를 통해 나온 값은 0과 1사이의 값으로 나오게 된다. 출력값에서 1이 의미하는 것은 함수의 입력값을 모두 통과시키는 것이고, 출력값에서 0이 의미하는 것은 입력값을 모두 삭제하는 것이다. 망각 게이트의 출력은 다음과 같이 표현된다.

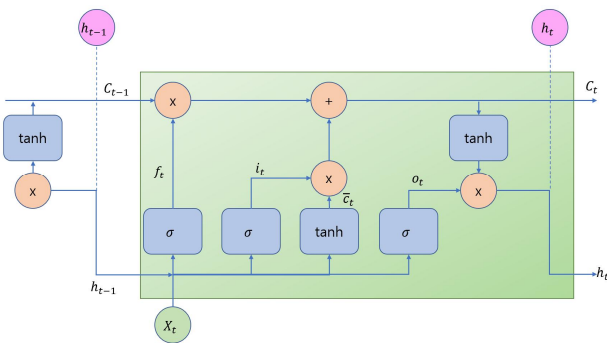


Fig. 2. Structure of LSTM block.
그림 2. LSTM 블록의 기본구조

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f). \quad (2)$$

여기서 W 는 레이어의 연결 계수를 의미하고, b 는 레이어의 바이어스값을 의미한다. 망각 게이트의 출력이 이전 단계의 블록상태 값과 곱해져 이전 단계 블록상태 값의 반영비율을 결정한다.

두 번째는 입력 게이트이다. 망각 게이트를 통과

한 값에 어떠한 값을 더해줄 것인지 선택하는 과정이다. 먼저 sigmoid 함수를 통과한 i 값은 새로운 입력을 얼마나 반영해줄 것인지 결정하는 역할이다. 새로 추가될 값의 후보는 이전 은닉층의 출력과 현재 입력의 tanh 활성화함수 레이어의 출력으로 결정된다. tanh 함수의 출력은 -1에서 1사이의 값으로 매칭된다. 새로운 값의 후보와 반영비율 값을 수식으로 표현하면 다음과 같다.

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i). \quad (3)$$

$$\bar{c}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c). \quad (4)$$

이 두 값들을 기반으로 현재 블록의 상태값을 업데이트해야 한다. 그림 2의 위쪽 수평선의 연산을 수식으로 표현하면 다음과 같다.

$$C_t = f_t * C_{t-1} + i_t * \bar{C}_t. \quad (5)$$

이제 마지막으로 이 블록의 출력을 결정하는 출력 게이트이다. 먼저 sigmoid 함수를 통과시켜 새로운 출력의 반영비율을 결정한다. 그리고 전 단계에서 계산한 블록 상태값을 tanh 레이어를 통과시켜 다시 새로운 출력 후보로 만든다. 이 두 값의 곱이 다음 은닉층과 현재 은닉층의 출력으로 블록을 빠져나가게 된다. 이를 수식으로 표현하면 다음과 같다.

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o). \quad (6)$$

$$h_t = o_t * \tanh(C_t). \quad (7)$$

이러한 일련의 과정을 통해 LSTM 블록은 입력을 받아 블록 상태값을 처리하고 출력을 내보낸다.

3. 지도학습

기계학습의 방법에는 크게 지도학습, 비(非)지도 학습 그리고 강화학습이 있다. 본 논문에서는 지도 학습을 이용하였기 때문에 지도학습에 대해 간략히 서술하겠다. 지도학습이란 모델을 학습시킬 때 입력데이터와 그에 대한 정답을 알려주어서 학습 방향을 정해주는 학습방법을 말한다.

지도학습은 다음과 같이 이루어진다. 먼저 입력데이터가 해당하는 정답과 같이 주어지는데, 모델을 입력만을 받아들인다. 그 입력에 해당하는 출력을 내면 정답과 값을 비교해본다. 이 오차값을 토대로

모델 내의 바이어스값과 연결계수의 값을 조정한다. 이 과정을 도식화하면 그림 3과 같이 나타난다.

이때 오차값을 표현하는 방식은 사용하는 손실함수에 따라 방식이 달라진다. 그리고 이 손실함수를 토대로 모델내의 여러 계수들이 최적의 값을 빠르게 찾아 나갈 수 있게 해주는 알고리즘을 최적화 알고리즘이라고 한다. 기계학습 기법에는 다양한 손실함수와 최적화 알고리즘이 존재한다.

어떤 함수와 알고리즘을 선택하느냐에 따라 모델의 학습 속도와 성능이 달라질 수 있다. 본 논문에서 사용한 모델의 손실함수와 최적화 알고리즘은 각각 Mean Squared Error(MSE) 함수와 Adam optimizer [14] 이다.

III. 시뮬레이션 환경 및 결과

1. 시뮬레이션 환경

본 연구에서는 20대 독신 남성의 가정을 모델로 4개의 가전제품을 사용하는 경우로 전력사용 패턴을 간략화 했다. 4개의 가전제품은 헤어드라이어, 전기밥솥, 커피포트 그리고 선풍기다. 해당 가전제품의 전력 소모량을 토대로 데이터를 생성하였다.

생성한 데이터를 이용해 모델의 구조와 여러 파라미터들을 실험하였고, 각각의 최적의 값을 도출했다. 실험에 사용한 파라미터는 LSTM층의 개수, LSTM 셀의 개수, look_back, epoch, batch size 등이다.




Fig. 3. Structure of supervised learning.

그림 3. 지도학습 기본구조

Table 1. Simulation parameters.

표 1. 시뮬레이션 파라미터

Parameters	Value
the number of LSTM layer	3
the number of LSTM cell	64
look_back	80
epoch	100
batch	7

2. 학습데이터

본 연구에서 이용한 학습데이터는 7월 한 달을, 검증과 테스트를 위한 데이터는 8월의 1주일씩을 설정하였다. 공휴일과 계절 상태를 데이터에 포함하였다. 사용한 데이터는 모두 30분에 한번 샘플링을 하고 그에 따라 30분간 이용한 데이터를 나타낸다. 사용한 데이터는 그림 4와 그림 5와 같다.

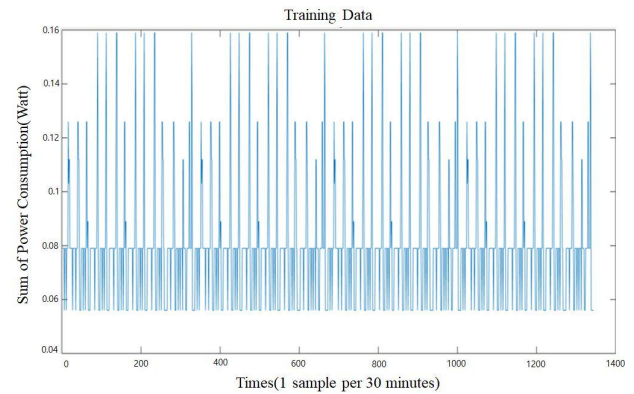


Fig. 4. Training data for power consumption.

그림 4. 전력 소모값에 대한 학습 데이터

그림 5의 앞쪽 절반은 학습 상태를 알아보고 학습 방향을 모델이 평가하는데 이용하는 검증 데이터로 이용하였고, 뒤쪽의 절반은 모델의 성능을 테스트하는데 이용하는 테스트 데이터로 사용하였다.

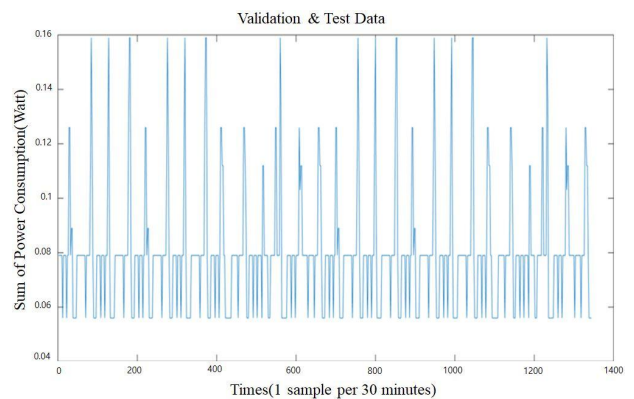


Fig. 5. Validation and test data for power consumption.

그림 5. 전력 소모에 대한 검증 및 테스트 데이터

생성한 학습 데이터를 토대로 다양한 학습 파라미터와 모델 구조를 테스트 하였다. 앞서 언급한대로, 실험을 통해 조정한 학습 파라미터들은 LSTM 층의 개수, LSTM 셀의 개수, look_back, epoch 그리고 batch size이다.

먼저 LSTM 층의 개수이다. LSTM 은닉층을 몇 개 사용한 모델인지 알 수 있는 파라미터이다. 본 연구에서는 1층, 2층, 3층 구조에 대해서 테스트를 진행했다. 결과를 간략히 소개하자면, 1층과 2층 구조는 디테일한 경향을 따라가지 못하는 성능을 보였다. 3층의 경우에는 만족스러운 결과가 나왔다. 그래서 층의 개수는 3층 구조로 선택하였다.

다음으로는 LSTM 셀의 개수이다. LSTM 은닉층에 LSTM 블록을 몇 개로 설정할 것인지 결정하는 파라미터이다. 셀의 개수가 너무 적으면 복잡한 패턴을 학습하지 못 할 것으로 예측하고 테스트를 진행하였다. 테스트를 진행하면서 최적의 값으로 64로 설정하였다.

look_back은 데이터셋 벡터의 크기를 몇으로 할 것인지 결정해주는 파라미터이다. 이 또한 실험을 통해 최적의 값을 80으로 설정했다.

Epoch는 주어진 데이터들을 몇 번 반복학습 할 것인지 정하는 파라미터이다. 같은 데이터를 학습 하더라도 반복학습을 수행하면 학습의 성능이 올라가는 경향이 있다. 하지만 이 값을 올리면 과적합에 빠지기도 한다. 그래서 본 연구에서는 epoch를 100회로 지정했다.

마지막으로 batch size는 몇 개의 데이터셋을 학습하고 내부 모델의 연결 계수들의 값을 수정할 것인지 정하는 파라미터이다. 이 값이 너무 크면 디테일한 경향을 따라가기 힘들 것이라 판단하여 이 값은 실험을 통해 7의 값으로 지정하였다.

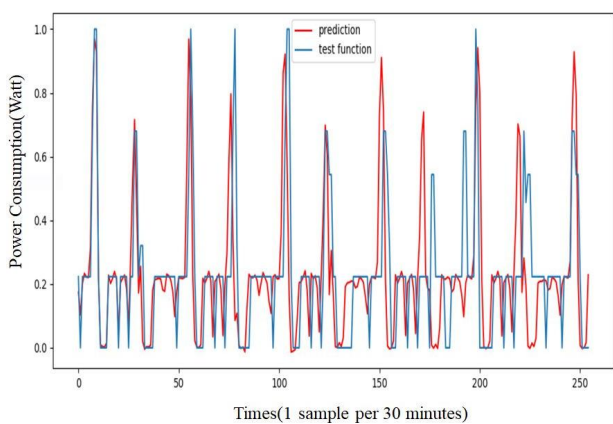


Fig. 6. Prediction result and test data.
그림 6. 예측 결과와 테스트 데이터

앞서 설정한 데이터와 파라미터를 통해 학습을 진행하였고, 테스트 데이터를 입력으로 학습된 모

델의 출력을 확인해보았다. 그 결과는 그림 6에 나타난다. 그림 7은 최종 예측결과에 따른 테스트 데이터와의 오차값 그래프를 나타낸다. 그림 6과 그림 7의 x축 한 샘플당 30분을 나타낸다.

오차 전체의 합을 테스트 함수 전체의 값으로 나눈 오차율은 0.2137 (21.37%)의 값을 갖는다. 이는 전력 공급 예비율 45.9% (2018년 8월 26일 오후 8시 기준, 한국전력)에 비해 24%이상 향상된 수치이다. 그러므로 현행의 예비율 책정방식 대신에 본 논문에서 제안하는 시스템을 도입한다면 전력 예비율을 줄여 효율적인 발전을 가능하게 할 것이다.

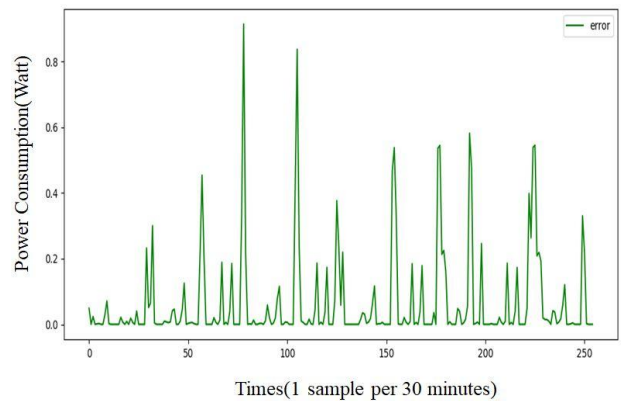


Fig. 7. Error of prediction result.
그림 7. 예측 결과에 대한 오차

IV. 결론

본 논문에서는 인공지능망에서 딥 러닝, 순환신경망, LSTM에 이르는 개념과 학습 방법으로써의 지도학습을 알아보았다. 그리고 한 가정의 전력 사용량을 4개의 가전제품 사용 모델로 축소해서 데이터를 생성하였고, 이 데이터를 토대로 다양한 모델을 테스트 했다. 테스트를 통해서 각각의 파라미터들이 갖는 최적의 값을 설정하였고, 이 파라미터들을 갖는 모델을 생성한 데이터로 학습시켰다. 마지막으로 학습시킨 모델의 결과와 오차율을 확인하였다. 그리고 마지막으로 현행 전력 예비율과 오차율을 비교해 효율성을 확인해 보았다.

실제 사용자의 데이터를 측정해서 데이터화 하고 학습시킨다면 축소된 모델이 아닌 실제 가정의 사용량 예측을 할 수 있는 시스템으로 확장이 가능하다. 하지만 한계도 예상된다. 환경적 요소와 같은 외적인 요소가 급변하는 구간, 예를 들면 온도가

급변하는 환절기와 같은 요소가 포함되면 모델은 예측을 하는데 어려움을 겪을 것이다. 추후 연구로써 전력 사용량만을 학습하는 모델이 아닌 다양한 환경변수 (온도, 조도 등)를 포함한 데이터를 학습하는 모델로 다양한 데이터를 학습시키고 예측하는 연구가 가능하다.

References

- [1] S. Kalyanaraman, "Back to the future: lessons for internet of energy networks," *IEEE Internet Computing*, vol.20, no.1, pp.60-65, 2016. DOI:10.1109/MIC.2016.19
- [2] Y. J. Lin, H. A. Latchman, M. Lee and S. Katar, "A power line communication network infrastructure for the smart home," *IEEE Wireless Communications*, vol.9, no.6, pp.104-111, 2002. DOI:10.1109/MWC.2002.1160088
- [3] K. B. Song, "Development of short-term load forecasting algorithm using hourly temperature," *Journal of KIEE*, vol.63, no.4, pp.451-454, 2014. DOI:10.5370/KIEE.2014.63.4.451
- [4] K. B. Song and S. K. Ha, "An algorithm of short-term load forecasting," *Journal of KIEE*, vol.53A, no.10, pp.529-535, 2004.
- [5] S. I. Kong, K. B. Song and Y. S. Baek, "The daily peak load forecasting in summer with the sensitivity of temperature," *Journal of KIEE*, vol.53A, no.10, pp.358-363, 2004.
- [6] S. B. Kong, M. S. Jang and S. K. Joo, "Short-term load forecasting for weekdays using a big data analysis," in *Proc. of 2015 Spring Conference of KIEE*, Seoul, pp.144-145, 2015.
- [7] H. N. Lee, J. H. Han and M. H. Lee, "Research of power peak estimation and prediction," *Korea Energy Economic Review*, vol.9, no.2, pp.83-99, 2010.
- [8] I. Goodfellow, *Deep Learning*, MIT Press, 2016.
- [9] S. P. Kim, *Deep Learning First Step*, Hanbit media, 2016.
- [10] K. Greff, R. K. Srivastava, J. Koutnik, B. R. Steunebrink and J. Schmidhuber, "LSTM: a search space odyssey," *IEEE Trans. Neural Networks and Learning Systems*, vol.28, no.10, pp.2222-2232, 2017. DOI:10.1109/TNNLS.2016.2582924
- [11] H. Salehinejad, S. Sankar, J. Barfett, E. Colak and S. Valaee, "Recent advances in recurrent neural networks," *arXiv preprint arXiv:1801.01078*, 2018.
- [12] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Proc. of the 25th International Conference on Neural Information Processing Systems*, Nevada, U.S.A., pp.1097-1105, 2012.
- [13] P. Sibi, S. A. Jones and P. Siddarth, "Analysis of different a activation function using back propagation neural networks," *Journal of Theoretical and Applied Information Technology (JATIT)*, vol.47, no.3, pp.1264-1268, 2013. DOI:10.1155/2012/490647
- [14] Z. Wang, "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

BIOGRAPHY

Dong-Gu Lee (student Member)



2012~present : BS course in
Wireless communications
Engineering, KwangWoon
University.

Soo-Hyun Kim (student Member)



2012~present : BS course in
Wireless communications
Engineering, KwangWoon
University.

Ho-Chul Jung (student Member)

2011~present : BS course in Wireless communications Engineering, KwangWoon University.

Young-Ghyu Sun (student Member)

2018 : BS degree in Wireless communications Engineering, KwangWoon University.
2018~present : MS Course in Wireless Communications Engineering, KwangWoon University.

Issac Sim (student Member)

2016 : BS degree in Wireless communications Engineering, KwangWoon University.
2016~present : PhD Course in Wireless Communications Engineering, KwangWoon University.

Yu-Min Hwang (Member)

2012 : BS degree in Wireless Communications Engineering, KwangWoon University.
2012~present : PhD Course in Wireless Communications Engineering, KwangWoon University.

Jin-Young Kim (Member)

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

2001~ present : Professor in Dept of Wireless Communications Engineering, KwangWoon University.