

## 특수일 분리와 예측요소 확장을 이용한 전력수요 예측 딥 러닝 모델

# Deep Learning Model for Electric Power Demand Prediction Using Special Day Separation and Prediction Elements Extention

박준호 · 신동하 · 김창복\*

가천대학교 에너지 IT학과

Jun-Ho Park, Dong-Ha Shin, Chang-Bok Kim\*

Department of Energy IT, Gachon University, 1342, Seongnam-daero, Sujeong-gu, Seongnam-si, Gyeonggi-do, 13120, Korea

### [요 약]

본 연구는 전력수요 패턴이 다른 평일과 특수일 데이터가 가지는 상관관계를 분석하여, 별도의 데이터 셋을 구축하고, 각 데이터 셋에 적합한 딥 러닝 네트워크를 이용하여, 전력수요예측 오차를 감소하는 방안을 제시하였다. 또한, 기본적인 전력수요 예측요소인 기상요소에 환경요소, 구분요소 등 다양한 예측요소를 추가하여 예측율을 향상하는 방안을 제시하였다. 전체데이터는 시계열 데이터 학습에 적합한 LSTM을 이용하여 전력수요예측을 하였으며, 특수일 데이터는 DNN을 이용하여 전력수요예측을 하였다. 실험결과 기상요소 이외의 예측요소 추가를 통해 예측율이 향상되었다. 전체 데이터 셋의 평균 RMSE는 LSTM이 0.2597이며, DNN이 0.5474로 LSTM이 우수한 예측율을 보였다. 특수일 데이터 셋의 평균 RMSE는 0.2201로 DNN이 LSTM보다 우수한 예측율을 보였다. 또한, 전체 데이터 셋의 LSTM의 MAPE는 2.74%이며, 특수일의 MAPE는 3.07%를 나타냈다.

### [Abstract]

This study analyze correlation between weekdays data and special days data of different power demand patterns, and builds a separate data set, and suggests ways to reduce power demand prediction error by using deep learning network suitable for each data set. In addition, we propose a method to improve the prediction rate by adding the environmental elements and the separating element to the meteorological element, which is a basic power demand prediction elements. The entire data predicted power demand using LSTM which is suitable for learning time series data, and the special day data predicted power demand using DNN. The experiment result show that the prediction rate is improved by adding prediction elements other than meteorological elements. The average RMSE of the entire dataset was 0.2597 for LSTM and 0.5474 for DNN, indicating that the LSTM showed a good prediction rate. The average RMSE of the special day data set was 0.2201 for DNN, indicating that the DNN had better prediction than LSTM. The MAPE of the LSTM of the whole data set was 2.74% and the MAPE of the special day was 3.07%.

**Key words :** Machine learning, Deep learning, Artificial neural network, Power Electric demand prediction, LSTM.

<https://doi.org/10.12673/jant.2017.21.4.365>



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.

Received 25 July 2016; Revised 1 August 2017  
Accepted (Publication) 25 August 2017 (30 August 2017)

\*Corresponding Author ; Chang-Bok Kim

Tel : +82-10-8908-3946

E-mail : cbkim@gachon.ac.kr

# I. 서론

전력수요예측은 전력계통의 안정적이고 경제적인 운용을 위해 필수적이며, 경쟁시장의 다양한 참여자에게 유용한 기본 정보로 사용된다. 전력수요예측은 각종 발전계획과 전력시스템의 운전비용 그리고 전력공급의 신뢰도를 위해 보다 예측오차를 감소하여야 한다.

전력수요 예측오차를 최소화하여 안정적이며 경제적인 전력계통의 운영을 위하여 많은 방법론들이 등장하였으며, 통계적 방법과 기계학습 방법으로 나눌 수 있다. 통계적인 방법은 회귀분석과 시계열분석이 있다. 회귀분석은 독립변수로 기상요소나 요일과 같은 요소를 사용하여, 종속변수인 전력수요의 통계를 분석한 회귀모델을 사용한다[1]-[2]. 시계열분석은 자기회귀, 이동평균, ARIMA(auto regressive integrated moving average), 지수평활법 등이 있다[3]-[5]. 시계열 분석과 회귀분석을 이용한 전력수요예측은 특정 이벤트에 다소 취약한 정확성을 보인다는 단점이 있다. 기계학습은 컴퓨터가 데이터를 학습하여 지능을 획득하는 빅 데이터의 핵심기술이다. 특히, 산업혁명 4.0 시대의 도래로 에너지 기술과 ICT(information and communication technologies) 기술이 융합되면서, 신경망 모델인 딥 러닝(deep learning)을 이용하여, 전력관리 및 수요예측에 대한 연구가 진행되고 있다[6]-[8].

전력수요는 다양한 이유로 인해 패턴이 변하는 비선형 모형이기 때문에, 부하의 규칙적 패턴에 근거한 대부분의 수요예측 알고리즘은 동일한 성능을 나타낼 수 없다. 특히 주말이나 공휴일과 같은 특수일 뿐 아니라 이상 기후 및 선거와 같은 사회적 이벤트 등 예외적인 상황이 발생한 경우에 대해서는 예측 결과가 현저히 낮게 나타낸다.

본 연구는 2013년에서 2016년까지의 전력수요와 기상데이터 그리고 다양한 예측요소를 이용하여, 비선형 데이터 학습에 적합한 DNN(deep neural network), LSTM(long short term memory)을 이용하여 전력수요예측을 하였다. 이를 위해 6개의 기상요소와 환경요소 및 구분요소를 사용하였으며, 특수일인 주말과 공휴일의 전력수요 패턴은 평일과 다르기 때문에, 전체 데이터 셋, 주말 데이터 셋, 주말과 공휴일을 포함한 특수일 데이터 셋으로 분류하였다. 또한, 모든 데이터 셋에 대해서 전력수요와 상관관계를 분석하여, 특수일에 대한 전력수요 예측오차를 감소할 수 있는 신경망 모델을 제안하였다. 이를 위해 전체 데이터는 DNN과 시계열 데이터 학습에 적합한 LSTM 학습하여 전력수요 예측오차를 비교하였다. 또한, 특수일 데이터 셋은 시계열 데이터가 아니기 때문에, DNN으로 학습하여, LSTM과 비교하였다.

본 논문은 2장에 관련연구로서 전력수요 및 기상요소의 상관관계와 LSTM 신경망에 대해서 서술하였다. 또한, 3장에 전력수요예측 딥 러닝모델을 제안하였으며, 4장에 실험결과를 나타냈으며, 마지막으로 결론에 대해서 서술하였다.

# II. 전력 수요

## 2-1 전력수요와 기온 상관관계

연구는 2013년에서 2016년에 대한 전력통계 정보시스템(electric power statistics information system)과 기상청의 전력수요 데이터와 기상 데이터를 이용한다. 기상청에서 예보하는 기상요소는 평균온도, 최저온도, 최대온도, 일강수량, 평균풍속, 평균상대습도, 일사량 등이 있으며, 이를 통해, 보조 기상요소로서 평균이슬점온도, 체감온도와 난방도일 등을 산출할 수 있다.

$$ST = T - 0.4 \times (T - 10) \times (1 - H) \tag{1}$$

$$HI_d = \sum_{i=1}^n [T_d(i) - 18] \tag{2}$$

여기서 ST는 체감온도, T는 온도(°C), V(km/h)는 풍속, H(%)는 습도, HI<sub>d</sub>는 d일의 난방도일, T<sub>d</sub>(i)는 시간 i의 기온이다.

기상요소는 지역마다 차이가 있기 때문에, 지역별 전력수요량 및 인구밀도 등을 이용하여, 지역별 가중치를 구하고, 수식(3)과 같이 대표기상요소를 산출해야 한다[9]. 표 1에 지역별 가중치에 대해서 나타냈다. 일반적으로 전력 수요는 주말이나 공휴일인 경우, 평일과 상이한 전력 수요 패턴을 가진다. 그림 1에 2016년 12월에서 2017년 2월에 대한 전력수요 온도패턴에 대해서 나타냈다.

표 1. 지역별 가중치.  
Table 1. Region weight.

Area	Seoul	Busan	Daegu	Daejeon	Gwangju
Weight	0.43	0.18	0.13	0.14	0.12

$$\begin{aligned} & \text{Representative meteorological element} \\ & = \text{Seoul meteorological element} \times \text{Seoul weight} + \\ & \quad \text{Busan meteorological element} \times \text{Busan weight} + \\ & \quad \text{Daegu meteorological element} \times \text{Daegu weight} + \\ & \quad \text{Daejeon meteorological element} \times \text{Daejeon weight} + \\ & \quad \text{Gwangju meteorological element} \times \text{Gwangju weight} + \end{aligned}$$




그림 1. 전력수요 및 온도 패턴.  
Fig. 1. Electric power demand and temperature pattern.

표 2. 전력수요와 온도 상관관계.

Table 2. Correlation of electric power demand and temperature.

Index	Minimum Temp.	Maximum Temp.	Dew Point	Sensible Temp.	Heating Degree
1	-0.195	-0.252	-0.183	-0.241	-0.226
2	-0.238	-0.296	-0.219	-0.287	-0.269
3	-0.224	-0.284	-0.205	-0.272	-0.256

그림 1은 전력수요와 온도를 정규화하고, 정규화된 온도에 대해서 |1-정규화 패턴을 그래프로 나타냈다. 그림에서 전력수요 및 온도의 패턴은 상관관계가 있으며, 주말 그리고 설 명절과 같은 공휴일은 전력 패턴이 평일과는 다름을 알 수 있다.

표 2에 2013년 부터 2016년까지의 최대전력수요와 최저기온, 최고기온, 이슬점온도, 난방도일, 체감온도 등 기상요소의 상관관계를 보였다. 표에서 1은 2013년 부터 2016년까지의 기상 및 전력 수요 전체 데이터 셋이다. 2는 평일을 제거한 주말 데이터 셋이며, 3은 주말 및 공휴일 등 특수 일을 포함한 데이터 셋이다. 표에서 전체 데이터 셋의 상관관계 보다 주말 및 공휴일을 포함한 데이터 셋의 상관관계가 높았음을 알 수 있다.

2-2 LSTM

딥 러닝은 기존의 신경망에 시그모이드(sigmoid) 함수의 문제점인 기울기 사라짐 문제를 제거하고, 초기 가중치 알고리즘을 통해, 중간층을 깊게 구성한 신경망이다. 기존 신경망은 방대한 학습 데이터에서 각각 하나의 입력패턴과 이에 대응하는 출력라벨만을 이용하며, 모든 입력패턴과 출력라벨이 독립적이라고 가정한다. 그러나 실제에는 과거의 데이터가 미래에 영향을 주는 시간에 종속적인 다양한 시계열 데이터가 있으며, 이전의 신경망은 시계열 데이터를 처리하기에 어려운 구조이다. RNN(recurrent neural network)은 동일한 신경망을 여러 개 복사하여 병렬로 체인 구조로 연결함으로써, 이전 신경망의 학습결과를 현재 신경망의 학습에 사용하는 것으로, 과거 시점의 데이터를 이용하여 현재를 예측할 수 있어, 시계열 데이터를 처리하는데 효과적이다. 그러나 RNN은 하나의 tanh 활성화함수를 가진 구조이며, 만약 체인의 길이가 길어질 경우 위치가 멀어질수록 과거의 학습 결과의 연결이 어려워지는 장기 의존성 문제가 있다. 그림 2에 LSTM의 구조에 대해서 나타냈다.

LSTM은 전체 체인을 관통하는 셀 스테이트(cell state)를 통해 과거 셀의 학습 결과를 큰 변함없이 전달하는 구조로 장기 의존성 문제를 해결한다[10]-[11]. LSTM은 첫번째 단계로 삭제할 정보를 결정하고, 두 번째 단계로 새로운 정보가 셀 스테이트에 저장할지 결정한다. 세 번째 단계는 셀 스테이트를 업데이트하고 마지막으로 어떤 출력 값을 출력할지를 결정한다.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{4}$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{5}$$




그림 2. LSTM 구조.

Fig. 2. LSTM structure.

$$\tilde{s}_t = \tanh(W_s \cdot [h_{t-1}, x_t] + b_s) \tag{6}$$

$$S_t = f_t * S_{t-1} + i_t * \tilde{s}_t \tag{7}$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{8}$$

$$h_t = o_t * \tanh(S_t) \tag{9}$$

여기서  $f_t$ 는 첫 번째 단계,  $i_t$ 와  $\tilde{s}_t$ 는 두 번째 단계,  $s_t$ 는 세 번째 단계,  $o_t$ ,  $h_t$ 는 마지막 단계의 출력이다. 또한,  $W$ 는 가중치,  $b$ 는 바이어스,  $s$ 는 셀 스테이트,  $t$ 는 타임스텝을 의미한다.

III. 수요예측 딥러닝 모델

본 연구는 2013년 부터 2016년까지의 전력통계 정보시스템과 기상청의 데이터를 이용하여, 최대전력수요와 최저기온, 최고기온, 일사량, 이슬점온도, 난방도일, 체감온도 등 전력수요 예측을 위해 6개의 기상요소를 사용하였다. 또한 환경요소 구분요소 등을 추가 사용하였다. 환경요소는 전기요금, 경제성장률과 같은 경제적인 요소이며, GDP(gross domestic product), 경제성장률, 전 산업 생산지수를 변수로 선정할 수 있다. 본 연구는 통계청의 전 산업 생산지수를 입력변수로 설정하였다. 구분요소는 전체 데이터 셋에서 평일과 특수일의 전력패턴이 다르기 때문에, 평일과 특수 일을 구분한 것으로 평일은 0 그리고 특수 일은 1로 하였다. 표 3은 본 연구에서 사용한 전력수요예측을 위한 요소와 신경망 입력 변수들에 대해서 나타냈다.

본 연구는 기상청에서 예보되는 기상요소이기 때문에 평일 전력 수요 값을 예측에 사용할 수 있다는 가정하였다. 따라서 딥 러닝 학습을 위해 필요한 출력인 전력수요를 당일 및 익일 전력수요로 하였다. 전체 데이터 셋은 시계열 으로 시계열 데이터 셋에 적합한 LSTM을 이용하여 전력 수요예측을 하였다.

표 3. 수요 예측요소 및 변수명.

Table 3. Demand prediction elements and variable name.

Minimum Temp.	Maximum Temp.	Solar Radiation	Dew Point
X1	X2	X3	X4
Sensible Temp.	Heating Degree	Production Index	Classification
X5	X6	X7	X8




그림 3. DNN 입출력모델.  
Fig. 3. DNN input output model.

또한, 전체 데이터에 대해서 동일한 입출력으로 DNN을 이용하여 학습하였다. 주말 및 특수일 데이터 셋은 시계열 데이터가 아니기 때문에, DNN을 이용하여 예측하였다. 그림 3에 DNN의 입출력 모델에 대해서 나타냈다. DNN은 입력 층을 8노드, 중간층을 각 층마다 16 노드 또는 32 노드로 하여 3층으로 설정하였으며, 출력 층은 1 노드로서 당일 또는 명일 최대전력으로 하였다.

그림 4에 LSTM 입출력 모델에 대해서 나타냈다. LSTM은 전력수요가 일주일 간격으로 유사한 패턴을 갖기 때문에, 일주일 단위로 학습하기 위해 타임스탬프(time stamp)를 7개로 하여, 7개의 LSTM셀로 구성하였다. 또한 각 LSTM셀은 6개의 기상요소와 환경요소 및 구분요소 등 8개의 데이터를 입력하였다. 이때 각 셀의 출력은 중간층으로 연결되며. 중간층의 노드는 16개 또는 32개로 하였다. 최종적으로 출력층에 출력 라벨로서 당일 또는 명일의 최대전력 수요를 사용하였다. 다음은 LSTM에 대한 텐서플로우 코드의 일부분이다.

```
lstm_cell=tf.contrib.nn.BasicLSTMCell(n_hidden, forget_bias=1.0)
outputs, states =tf.contrib.nn.static_rnn(lstm_cell, x_split, dtype=tf.float32)
pred =tf.matmul(outputs[-1], weights) + biases
cost =tf.reduce_mean(tf.square(pred-y))
optimizer=tf.train.AdamOptimizer(learning_rate=learning_rate).minimize(cost)
```

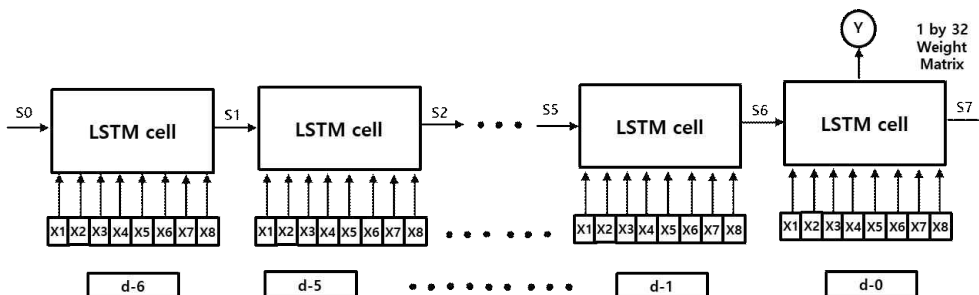


그림 4. LSTM 입출력 모델.  
Fig. 4. LSTM input output model.

위 코드는 변수 n\_hidden개의 중간층을 갖는 LSTM 셀을 생성하고, 생성된 LSTM 셀을 타임스탬프 변수 x\_split개 만큼 병렬로 연결하여, 딥 러닝 네트워크를 구축하였다. 또한, 각 LSTM 셀에 전력수요예측요소의 입력으로 예측값을 신경망을 통해 출력하고, 예측값과 실제값에 대한 오차를 계산하며, 최종적으로 AdamOptimizer 최적화 알고리즘을 이용하여, 오차를 줄이는 과정에 대해서 나타냈다. 텐서플로우는 이러한 과정이 하나의 그래프로 구축되며, 데이터 입력과 세션 객체의 실행으로 실제값과 예측값의 오차를 줄일 수 있는 학습을 통해 가중치와 바이어스 값을 조절 한다.

#### IV. 실험결과

본 연구는 Linux Ubuntu 16.04 LTS 운영체제, Python 2.7, 통계 오픈소스인 R, Tensorflow 1.0을 사용하였다. 실험을 위한 학습데이터는 2013년도 1월부터 2016년도 9월 데이터를 사용하였으며, 테스트 데이터는 2016년도 10월부터 12월까지를 사용하였다. 딥 러닝은 작은 데이터 입출력으로 학습하는 것이 효율적이기 때문에, 입력 데이터를 정규화하였다. 그러나 평일과 특수일을 구분하기 위한 구분요소는 0과 1의 값으로 정규화하지 않았으며, 출력 값은 명일의 최대전력량을 10000으로 나누어 실험하였다. 전력수요예측의 정확성은 오차율을 통해 확인할 수 있다. 본 연구는 다음과 같이 평균 제곱근오차(root mean square error)와 평균 백분율 오차율(mean absolute percentage error)을 사용하였다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (actual - predict_i)^2}{n}} \tag{10}$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{actual - predict}{actual} \right| \tag{11}$$

표 4에 전체 데이터 셋에 대해서 기상요소로 구성된 데이터 셋, 환경요소를 추가한 데이터 셋, 환경요소와 구분요소를 추가한 데이터 셋에 대한 LSTM을 이용한 실험결과를 나타냈다.

표 4. 예측요소 추가 결과.

Table 4. Prediction element additional result.

		A	B	C	D
Today Electric Power	Average RMSE	0.6276	0.6023	0.3037	0.2597
	Minimum RMSE	0.6166	0.5811	0.2546	0.239
Tomorrow Electric Power	Average RMSE	0.641	0.6339	0.3611	0.3212
	Minimum RMSE	0.6362	0.6079	0.3152	0.2726

실험결과는 오차율은 중간층 16과 32가 비슷하였으나 32층의 실험결과가 좀 더 안정적이었다. 평균오차는 5회 반복 실험 결과의 평균이며, 최소오차는 가장 좋은 오차율이다. 표에서 A는 최저기온, 최고기온, 이슬점온도, 난방도일, 체감온도 등 기본 적인 기상요소 B는 환경요소추가, C는 구분요소 추가, D는 일사량을 추가한 것이다.

실험결과 기본적인 기상요소에 일사량과 환경요소 그리고 구분요소 등을 추가한 실험결과에 대한 상관관계와 RMSE가 향상됨을 알 수 있다. 또한, 당일 기상요소에 대한 당일 전력수요 값에 대한 결과가 명일 전력수요 값에 대한 결과보다 예측결과가 우수했다. 특히, 본 연구에서 전력수요 예측요소 중 평일과 특수일을 구분하는 구분요소의 사용에 의해 상당한 예측오차 감소를 보였다.

전력수요예측요소를 모두 포함한 데이터 셋 3에 대해서 LSTM 시계열 딥 러닝 네트워크를 이용하여 학습을 하였으며, 시계열 네트워크가 아닌 DNN에 대해서 학습하여 결과를 비교하였다. 다음은 LSTM, DNN에 대한 결과를 나타냈다.

실험 결과는 데이터 셋을 5회 반복 실험하여, 평균값을 나타낸 것이다. 표에서 당일 데이터 셋에 대해서 평균오차가 LSTM은 0.2799, 0.2597이며, DNN은 0.5474이다. 또한, 명일 데이터 셋에 대해서 평균오차가 LSTM은 0.3253, 0.32124였으며, DNN은 0.5474였다. 전체 데이터 셋은 기본적으로 시계열이기 때문에, 시계열 데이터 학습 딥 러닝 네트워크인 LSTM의 학습결과가 DNN 보다 좋았음을 알 수 있다. 전체 데이터 셋의 LSTM의 가장 우수한 MAPE는 2.74%을 보였다, 그림 5에 LSTM의 실제값과 예측값에 대한 그래프를 나타냈다.

표 5. 전체 데이터 셋 결과.

Table 5. Entire data set result.

		LSTM(16)	LSTM(32)	DNN
Today Electric Power	Average RMSE	0.2799	0.2597	0.5474
	Minimum RMSE	0.2382	0.239	0.5279
Tomorrow Electric Power	Average RMSE	0.3253	0.32124	0.5675
	Minimum RMSE	0.3178	0.2726	0.5539



그림 5. RNN 예측결과.

Fig. 5. RNN prediction result.

표 6. DNN 실행결과.

Table 6. DNN execution result.

Weekend		Weekend and Special Day	
Average RMSE	Minimum RMSE	Average RMSE	Minimum RMSE
0.2205	0.2034	0.2201	0.2097

평일과 특수일은 시계열 데이터가 아니기 때문에, DNN으로 실험하였다. 표 6에 주말 및 주말에 공휴일을 포함한 특수 일에 대한 DNN 실험결과에 대해서 나타냈다.

실험 결과는 데이터 셋을 5회 반복 실험하여, 평균값을 나타낸 것이다. 표에서 주말 데이터 셋은 평균오차가 0.2205이며, 최소오차가 0.2034이다. 또한, 특수일 데이터였다. 셋은 평균오차가 0.2201이었으며, 최소오차가 0.2097이다. 특수일의 가장 우수한 MAPE는 3.07%를 보였다. 표 5와 표 6에서 특수일 데이터 셋을 이용한 DNN의 결과가 LSTM의 결과보다 대략 평균 0.03의 오차율 향상을 보였다.

## V. 결론 및 향후 과제

본 연구는 전력수요 패턴이 다른 평일과 특수일 데이터가 가지는 상관관계를 분석하여, 별도의 데이터 셋을 구축하여, 각 데이터 셋에 적합한 딥 러닝 네트워크를 통해 전력수요예측 오차를 감소하는 방안을 제시하였다. 본 실험 결과를 통해 전력수요예측은 보다 다양한 기상요소와 예측향상을 도모할 수 있는 다양한 요소를 통해 예측율이 향상되었다. 특히, 전력수요 예측요소 중 평일과 특수일을 구분하는 구분요소의 사용에 의해 상당한 예측오차 감소를 보였다. 또한, 전체 데이터에 대한 전력수요예측은 시계열 딥 러닝 네트워크인 LSTM이 우수한 예측율을 보였으며, 특수 일에 대한 전력수요예측은 DNN이 우수한 예측율을 보였다.

본 연구는 일 단위의 데이터를 사용하였으나 시간 단위의 데이터와 방대한 기상요소 빅 데이터를 사용하면, 높은 예측율 향상이 기대된다. 더불어 본 연구에서 나타난 것과 같이 전력수요 예측 향상을 위한 다양한 딥 러닝 입력 요소에 대한 연구가 필요하다. 최근 딥 러닝 네트워크 뿐 아니라 DQN(deep

Q-network)과 같은 강화학습 등과 같은 인공지능이 산업혁명 4.0 시대의 핵심기술로 발전하고 있다. 따라서 다양한 환경에 비선형적으로 변동하는 전력수요예측을 위해 보다 적절한 입출력 모델과 딥러닝 및 강화학습 모델에 대한 지속적인 연구가 필요하다.

### Acknowledgments

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20174030201470)

### References

[1] B. G. Koo, H. S. Kim, H. S. Lee, and J. H. Park, "Short-term electric load forecasting for summer season using temperature data," *The Journal of the Korean Institute of Electrical Engineers*, Vol. 64, No. 8, pp. 1137-1144, Aug. 2015.

[4] H. W. Jung, S. Y. Kim, K. B. Song, "Weekly maximum electric load forecasting method for 104 weeks using multiple regression models," *The Journal of The Korean Institute of Electrical Engineers*, Vol. 53. No. 9, pp. 1186-1191, Sep. 2014.

[5] S. Y. Kim, H. W. Jung, J. D. Park, S. M. Baek, W. S. Kim, K. H. Chon, and K. B. Song, "Weekly maximum electric load forecasting for 104 weeks by seasonal ARIMA

model," *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers*, Vol. 28, No 1, pp. 50-56, Jan. 2014.

[6] M. K. Kim, and C. E. Hong, "The artificial neural network based electric power demand forecast using a season and weather informations," *The Journal of the Korean Institute of Electrical Engineers*, Vol. 53, No. 1, pp. 71-78, Jan. 2016.

[7] D. H. Shin, C. B. Kim, "A study on deep learning input pattern for summer power demand prediction," *Journal of Korean Institute of Information Technology*, Vol. 14, No. 11, pp. 127-134, Nov. 2016.

[8] H. S. Kim, H. C. Song, S. K. Ko, B. T. Lee, and J. W. Shin, "RNN-LSTM based short-term electricity demand forecasting using holiday information," in *conference of the Institute of Eelectronics Engineers of Korea*, Gwangju: Korea, pp. 552-555, Nov. 2016

[9] J. H. Lim, S. Y. Kim, J. D. Park, and K. B. Song, "Representative temperature assessment for improvement of short-term load forecasting accuracy," *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers*, Vol. 27, No. 6, pp. 37 - 43, May. 2013.

[10] F. A. Gers, N. N. Schraudolph, and J. Schmidhuber, "Learning precise timing with LSTM recurrent networks," *Journal of Machine Learning Research* 3, pp. 115-143, Mar. 2002.

[11] Christopher Olah, Understanding LSTM Networks, Github blog [Internet]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>



**박 준 호 (Jun-Ho Park)**

2015 8월 : 가천대학교 에너지IT학과 (공학사)  
2015년 9월 ~ 현재 : 가천대학교 IT융합공학과 석사 과정  
관심분야 : 전력전자, 로봇 제어, IOT, 딥 러닝, 빅 데이터,



**신 동 하 (Dong-Ha Shin)**

2016년 2월 : 가천대학교 에너지IT학과 (공학사)  
2016년 3월 ~ 현재 : 가천대학교 대학원 IT융합공학과 석사 과정  
관심분야 : 딥러닝, 빅 데이터, IOT, 로봇제어, 로봇 액추에이터



**김 창 북 (Chang-Bok Kim)**

1986년 2월 : 단국대학교 전자공학과 (공학사)  
1989년 2월 : 단국대학교 전자공학과 (공학석사)  
2009년 2월 : 인천대학교 컴퓨터 공학과 (공학박사)  
1994년 ~ 현재 : 가천대학교 IT대학 에너지 IT학과 교수  
관심분야 : 빅 데이터 마이닝, 분산처리시스템, 사물인터넷, 마이크로그리드