

# 에너지인터넷에서 1D-CNN과 양방향 LSTM을 이용한 에너지 수요예측

## Prediction for Energy Demand Using 1D-CNN and Bidirectional LSTM in Internet of Energy

정 호 철\*, 선 영 규\*, 이 동 구\*, 김 수 현\*, 황 유 민\*, 심 이 삭\*, 오 상 근\*\*,  
송 승 호\*\*\*, 김 진 영\*

Ho Cheul Jung\*, Young Ghyu Sun\*, Donggu Lee\*, Soo Hyun Kim\* Yu Min Hwang\*,  
Issac Sim\*, Sang Keun Oh\*\*, Seung-Ho Song\*\*\* and Jin Young Kim\*

### Abstract

As the development of internet of energy (IoE) technologies and spread of various electronic devices have diversified patterns of energy consumption, the reliability of demand prediction has decreased, causing problems in optimization of power generation and stabilization of power supply. In this study, we propose a deep learning method, 1-Dimension Convolution and Bidirectional Long Short-Term Memory (1D-ConvBLSTM), that combines a convolution neural network (CNN) and a Bidirectional Long Short-Term Memory (BLSTM) for highly reliable demand forecasting by effectively extracting the energy consumption pattern. In experimental results, the demand is predicted with the proposed deep learning method for various number of learning iterations and feature maps, and it is verified that the test data is predicted with a small number of iterations.

### 요 약

에너지인터넷 기술의 발전과 다양한 전자기기의 보급으로 에너지소비량이 패턴이 다양해짐에 따라 수요예측에 대한 신뢰도가 감소하고 있어 발전량 최적화 및 전력공급 안정화에 문제를 야기하고 있다. 본 연구에서는 고신뢰성을 갖는 수요예측을 위해 딥러닝 기법인 Convolution neural network(CNN)과 Bidirectional Long Short-Term Memory(BLSTM)을 융합한 1Dimension-Convolution and Bidirectional LSTM(1D-ConvBLSTM)을 제안하고, 제안한 기법을 활용하여 시계열 에너지소비량에 대한 소비패턴을 효과적으로 추출한다. 실험 결과에서는 다양한 반복학습 횟수와 feature map에 대해서 수요를 예측하고 적은 반복학습 횟수로도 테스트 데이터의 그래프 개형을 예측하는 것을 검증한다.

*Key words : CNN, LSTM, 1D-ConvBLSTM, Energy prediction, Internet of Energy*

---

\* Dept. of Electronic Convergence Engineering, Kwangwoon University

\*\* Dept. of Power Electronics, PLASPO Co., Ltd.

\*\*\* Dept. of Electric Engineering, Kwangwoon University

★ 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. 8, 2019; revised Mar. 24, 2019; Accepted Mar. 26, 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.

## I. 서론

최근 인공지능기술의 발전으로 드론, 자율 주행 자동차, 의료 전자기기, 스마트폰, 스마트시티, 음성 인식, CCTV 등 다양한 분야에 딥러닝이 적용되고 있다[1-4]. 특히 데이터 기반 예측 분야에 있어서 머신러닝, 딥러닝에 관한 연구가 많이 진행되고 있는 중이다[5, 6]. 에너지소비량 데이터는 시계열 데이터이다. 기존의 시계열 데이터를 기반으로 예측하는 연구들은 주로 딥러닝 알고리즘을 이용한다 [7, 8]. 딥러닝 알고리즘에는 Deep Neural Network (DNN), Recurrent Neural Network(RNN), Long Short-Term Memory(LSTM) 등 다양한 종류의 알고리즘이 개발되었으며 본 논문에서는 CNN과 LSTM 알고리즘을 이용한다. RNN은 시계열 데이터를 반복적으로 학습시키는 딥러닝 알고리즘의 한 종류이다. RNN은 데이터 학습과정에서 이전 RNN의 출력데이터가 현재RNN의 출력 데이터에 영향을 주는 구조이다. 그래서 현재의 학습과 과거의 학습의 연결이 가능해지며 연속적이고 반복적인 학습에 유용하지만 너무 먼 과거의 데이터를 사용할 경우 예측 성능이 저하되는 특징을 가지고 있다. LSTM은 RNN기반 딥러닝 알고리즘의 한 종류로 순서 또는 시간의 측면을 고려하여 반복적인 학습을 한다. LSTM은 유전자, 손글씨, 음성신호, 센서 데이터, 주가 등 예측 및 분류 연구에 주로 이용되고 있다[9]. 최근 LSTM의 구조를 변형시켜 예측 성능을 개선시키는 연구가 많이 진행되고 있다 [10-11]. 또한, RNN과 LSTM을 이용한 예측 연구뿐만 아니라 CNN을 이용하여 시계열 데이터 기반 예측 연구가 많이 진행되고 있다[8]. CNN은 딥러닝 분야에서 2차원 이미지 데이터를 활용하여 이미지 분류 및 세분화, 객체 인식, 컴퓨터 비전, 이미지 분석에 사용되는 주로 사용되는 알고리즘이다. 주로 2차원 데이터를 이용하는 CNN을 1차원 시계열 데이터에 활용하여 데이터 특성 추출, 데이터 예측 분석 등에 적용이 가능하다[12-14].

이에 본 연구에서는 시계열 데이터 세트의 특성을 추출하는 장점을 가진 CNN과 시계열 데이터 세트의 과거 정보와 미래 정보를 모두 고려하여 다음 단계의 시계열 데이터를 예측하는 LSTM의 한 종류인 BLSTM을 결합한 알고리즘인 1D-ConvBLSTM 알고리즘을 제안한다. 1D-ConvBLSTM 알고리즘

으로 입력된 시계열 데이터는 CNN계층을 통과하여 데이터 특징이 추출이 되고나서 과거와 미래의 정보를 이용하는 BLSTM계층을 통과하므로 더 정확하게 시계열 데이터를 예측한다. 제안한 알고리즘의 시계열 데이터 예측 성능 확인을 위해 1D-ConvBLSTM 알고리즘의 변수에 따라 성능을 분석하여 알고리즘의 예측 성능을 최적화한다.

본 논문은 다음과 같이 구성된다. 2장은 딥러닝 알고리즘인 CNN, RNN, LSTM, BRNN, BLSTM에 대해 설명하고 3장은 본 연구에서 제안하는 알고리즘인 1D-ConvBLSTM에 대해 설명한다. 4장에서는 본 연구에서 이용하는 입력 데이터의 형태와 설정한 시뮬레이션 환경을 설명하고 시뮬레이션 결과와 결과에 대한 분석을 보여준다. 마지막으로 5장에서는 결론으로 마무리 짓는다.

## II. 딥러닝 알고리즘

### 1. CNN

CNN은 딥러닝 알고리즘의 한 종류로, 격자 형태로 배열된 데이터를 처리 하는 것에 특화되어 데이터의 패턴을 식별하는 것에 대하여 효과적인 신경망이다. 따라서 CNN은 공유 파라미터로 사용할 수 있는 다수의 필터를 활용하여 2차원의 경우 이미지의 공간 정보를 유지하며 인접 이미지와의 특징을 효과적으로 추출하며 학습한다. CNN은 최소한의 파라미터와 전처리 과정을 통한 보다 간편한 학습을 가능하게 하는 장점이 있다. 다음은 CNN의 입력데이터에 따른 출력 값의 수식이다.

$$s(t) = (x*w)(t) = \sum x(a)w(t-a). \quad (1)$$

$$s(i,j) = (I*K)(i,j) = \sum_m \sum_n I(m,n)K(i-m,j-n). \quad (2)$$

수식1은 1차원 입력 데이터에 대한 CNN계층의 출력 수식이다.  $x$ 는 입력 데이터이고  $w$ 는 kernel map이고  $s(t)$ 는 출력계층인 feature map이다. 수식 2는 2차원 입력 데이터에 대한 CNN계층의 출력 수식이다.  $I$ 는 입력 데이터이며  $K$ 는 kernel map이고  $s(i, j)$ 는 출력계층인 2차원 feature map이다. 그림 1은 2차원 입력 데이터에 대한 CNN알고리즘의 구조도이다. 그림 1을 살펴보면 CNN알고리즘은 네 단계로 구성된다.

첫 단계에서 입력데이터  $I(m,n)$ 로 가중함수를 가

지고 있는 kernel이 일정한 흐름으로 순회하며 다수의 합성곱을 병렬로 연산한다.




Fig. 1. Structure of 2-D CNN algorithm.  
그림 1. 2차원 CNN알고리즘 구조

두 번째 단계에서는 병렬로 연산한 값이 활성화 함수를 거치게 되며 입력 데이터에 대한 특징을 검출하여 feature map으로 출력된다.

세 번째 단계에서는 Pooling계층에서 Pooling 함수를 사용해서 feature map에 검출된 특징 데이터를 줄여 주는 작업을 진행한다. CNN알고리즘은 앞서 설명한 것과 같이 CNN계층과 Pooling계층의 반복을 통하여 데이터의 특성을 추출한다.

마지막 단계에서는 CNN계층과 Pooling계층으로 추출한 데이터 세트를 Fully Connected계층을 통하여  $n \times m$  행렬로 구성된 데이터를  $1 \times n$  열벡터 배열로 데이터구조를 변형하여 데이터의 특징을 분류한다.

그림 2는 1D-CNN알고리즘의 구조도이다. 1D-CNN 알고리즘도 2D-CNN 알고리즘의 학습과 같이 CNN계층과 Pooling계층으로 학습이 진행이 된다.

**2. RNN**

RNN이란 시계열 데이터와 같은 순차적인 정보를 처리하는 딥러닝 알고리즘이다. 그림 3은 RNN 알고리즘의 구조이다. 그림 3의 왼쪽 RNN 구조를 순차적 순서에 대하여 펼치면 그림 3의 오른쪽 그림과 같은 구조가 된다. 여기서  $X$ 는 입력층,  $h$ 는 출력층,  $A$ 는 은닉층을 나타낸다.

RNN알고리즘을 살펴보면 입력값은 시간에 따라 순차적으로 입력층을 통해 은닉층으로 들어간다. 은닉층의 뉴런은 각각의 시점에서 바로 이전 시점의 은닉층의 뉴런에서 나온 값을 계속해서 자신의 입력으로 보내는 재귀적 활동을 한다.




Fig. 2. Structure of 1-D CNN algorithm.  
그림 2. 1차원 CNN알고리즘 구조




Fig. 3. Structure of Recurrent Neural Network.  
그림 3. RNN 구조




Fig. 4. Structure of LSTM.  
그림 4. LSTM 구조

이 두 값을 기반으로 입력이 모두 들어갈 때까지 출력값을 출력하는 과정이 반복된다.

**3. LSTM**

LSTM알고리즘은 RNN알고리즘의 구조상 데이터양이 많으면, 오랜 과거의 시계열 데이터가 반영이 되지 않는 문제점을 해결하기 위해 개발된 알고리즘이다. RNN알고리즘에서 은닉층을 정보 흐름을 제어하는 게이트 시스템인 망각 게이트, 입력 게이트, 출력게이트로 변형하여 오랜 과거 시계열 데이터를 현재의 출력층에 반영시킨다.

그림 4 [13]는 LSTM알고리즘의 구조이다. 그림 4를 보면  $X$ 는 입력층,  $h$ 는 출력층,  $A$ 는 망각, 입력, 출력게이트로 변형한 은닉층이다.

#### 4. BRNN

BRNN알고리즘은 RNN알고리즘의 한 종류로 기존의 RNN알고리즘을 응용한 딥러닝 알고리즘이다. 그림 5 [15]는 BRNN알고리즘의 구조도이다. 그림 5를 살펴보면, 입력계층, 포워드계층, 백워드계층, 출력계층으로 BRNN알고리즘이 구성된다. 포워드계층과 백워드계층은 RNN알고리즘의 은닉층과 같은 역할을 한다.




Fig. 5. Structure of BRNN.

그림 5. BRNN의 구조도

#### 5. BLSTM

BLSTM알고리즘은 BRNN알고리즘과 LSTM알고리즘을 결합한 딥러닝 알고리즘이다. 그림 6은 BLSTM알고리즘의 구조도이다. 그림 6을 살펴보면 BLSTM알고리즘은  $X$ 는 입력계층,  $F$ 는 망각게이트, 입력게이트, 출력게이트로 변형한 포워드계층,  $B$ 는 망각게이트, 입력게이트, 출력게이트로 변형한 백포워드계층,  $Y$ 는 BLSTM 출력계층으로 구성된다.

데이터 입력 시간을  $t$ 라고 할 때, 망각게이트 출력값, 입력게이트 출력값, 출력게이트 출력값, 포워드계층의 상태값, BLSTM알고리즘의 상태 갱신 후보값의 수식은 다음과 같다.

$$f_{tF} = \sigma(W_{fF} \cdot [F_{t-1F}x_{tF}] + b_{fF}), \quad (14)$$

$$i_{tF} = \sigma(W_{iF} \cdot [h_{iF}x_{tF}] + b_{iF}), \quad (15)$$

$$\tilde{C}_F = \tanh(W_{CF} \cdot [F_{t-1F}x_{tF}] + b_{cF}), \quad (16)$$




Fig. 6. Structure of BLSTM.

그림 6. BLSTM의 구조도

$$C_{tF} = f_{tF} * C_{t-1F} + i_{tF} * \tilde{C}_{tF}, \quad (17)$$

$$O_{tF} = \sigma(W_{oF}[F_{t-1F}X_{tF}] + b_{oF}), \quad (18)$$

$$F_{tF} = O_{tF} * \tanh(C_{tF}). \quad (19)$$

$W$ 는 포워드계층 가중치,  $b$ 는 바이어스,  $F_{t-1F}$ 은 이전 포워드계층 상태값,  $h_{iF}$ 는 현재 포워드계층 알고리즘의 상태 후보값,  $x$ 는 시계열 입력 데이터,  $f_{tF}$ 는 포워드계층의 망각 게이트 출력값,  $i_{tF}$ 는 입력 게이트의 출력값,  $\tilde{C}_{tF}$ 는 포워드 계층의 현재 상태의 출력 후보값,  $C_{t-1F}$ 는 이전 포워드계층의 상태값,  $X_{tF}$ 는 시계열 입력데이터,  $C_{tF}$ 는 포워드계층의 현재상태의 상태값이다.

포워드계층은 시계열 입력데이터는 시간  $t=1$ 부터  $t=T$ 까지의 데이터이다. 포워드계층에서 진행과정은 LSTM알고리즘의 과정과 동일하다. 백워드계층에 대한 수식은 다음과 같다.

$$f_{tB} = \sigma(W_{fB} \cdot [F_{t-1B}x_{tB}] + b_{fB}). \quad (20)$$

$$i_{tB} = \sigma(W_{iB} \cdot [h_{iB}x_{tB}] + b_{iB}). \quad (21)$$

$$\tilde{C}_{tB} = \tanh(W_{CB} \cdot [F_{t+1B}x_{tB}] + b_{cB}). \quad (22)$$

$$C_{tB} = f_{tB} * C_{t+1B} + i_{tB} * \tilde{C}_{tB}. \quad (23)$$

$$O_{tB} = \sigma(W_{oB}[F_{t+1B}X_{tB}] + b_{oB}). \quad (24)$$

$$B_{tB} = O_{tB} * \tanh(C_{tB}). \quad (25)$$

$W$ 는 포워드계층 가중치,  $b$ 는 바이어스,  $F_{t-1B}$ 는 이전 백워드계층 상태값,  $h_{iB}$ 는 현재 백워드계층 알고리즘의 상태 후보값,  $x$ 는 시계열 입력 데이터,  $f_{tB}$ 는 백워드계층의 망각 게이트 출력값,  $i_{tB}$ 는 입력 게이트의 출력값,  $\tilde{C}_{tB}$ 는 백워드계층의 현재 상태의

출력 후보값,  $C_{t-1B}$ 는 이전 백워드계층의 상태값,  $X_{tB}$ 는 시계열 입력데이터,  $C_{tB}$ 는 백워드계층의 현재상태의 상태값이다.

백워드계층은 시계열 입력데이터는 시간  $t=T$ 부터  $t=1$ 까지의 데이터이다. 백워드계층에서 진행과정은 LSTM알고리즘의 과정과 동일하다.

BLSTM알고리즘의 출력값의 수식은 다음과 같다.

$$Y_t = W_{FY}F_{tF} + W_{BY}B_{tB} + b_y \quad (26)$$

출력계층은 과거 포워드계층의 LSTM알고리즘 출력값과 미래의 백워드계층의 LSTM알고리즘 출력값을 결합하여 결과값을 출력하는 과정이 반복된다. 과거와 미래의 데이터에 모두 의존함으로써 BRNN의 경우 RNN의 오랜 과거 시계열 데이터가 반영이 되지 않는 문제점을 LSTM을 결합하여 BRNN의 문제점을 개선한다.

### III. 제안하는 에너지 소비량 예측모델

#### 1. 1D-ConvBLSTM 시스템 모델

본 연구에서 제안하는 1D-ConvBLSTM 모델은 CNN과 BLSTM을 결합하여 시계열 데이터에 대해 작은 반복학습으로 최적의 학습효과를 내기위한 에너지 소비량 예측 알고리즘이다.

1D-ConvBLSTM 모델의 구성은 세 가지 단계로 나누어진다. 첫 번째로 CNN과 MaxPooling 3계층 구조이다. 첫 번째 단계에서는 시계열 데이터의 주기적, 비주기적 특성을 CNN계층에서 추출하여 출력값으로 Feature map을 생성한다. 추출된 특성 데이터의 크기를 줄여주기 위해 Max Pooling 계층을 이용한다. Max pooling은 feature map의 최댓값을 선정한다. 이 과정을 3번 반복하여 시계열 데이터의 주기적 비주기적 특성들은 추출하며 데이터의 크기는 처음보다 많이 감소된다.

두 번째 단계는 BLSTM계층의 심층 반복학습을 진행한다. BLSTM계층은 반복연산을 수행함으로써 CNN을 통하여 출력된 특징 데이터의 과거 데이터와 미래 데이터의 관계를 학습한다. 학습된 관계를 기반으로 미래의 데이터를 예측한다.

Dropout계층의 Dropout은 데이터 연산량과 계층의 증가로 과적합에 빠지는 문제를 해결한다.

세 번째 단계는 Flatten계층과 Dense계층으로 구

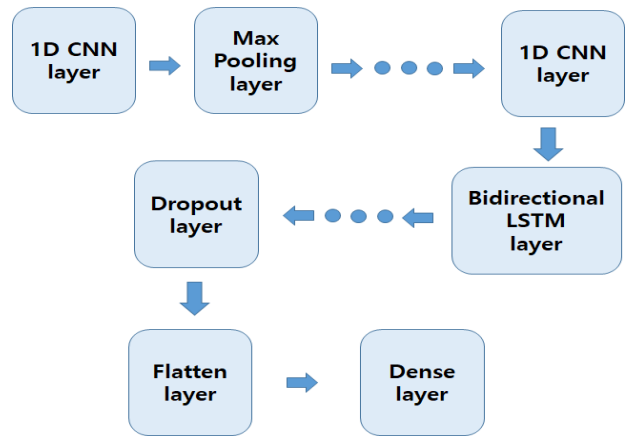


Fig. 7. Structure of proposed energy consumption prediction model.

그림 7. 제안하는 에너지 소비량 예측 모델 구조도

성된다. Flatten계층은 다차원 행렬화된 데이터를 1차원 시계열 데이터로 변환시켜주는 계층이다.

Dense계층은 입출력 모두를 연결해주는 계층이다.

### IV. 시뮬레이션 환경 및 결과

#### 1. 실험 데이터

본 연구에서 사용한 에너지 소비량 데이터는 UMass Trace Respository에서 제공한 가정 단위 에너지 소비량 데이터이다. 실험 데이터는 2014년 1월 1일부터 2014년 1월 31일까지 총 31일의 일일 에너지 소비량 데이터를 사용하였다. 하루 기준 15분 간격으로 샘플링하여 96개의 샘플을 한 프레임으로 구성하여 학습을 진행한다. 학습 데이터는 그림 8과 같다. 테스트 데이터는 그림 9와 같고 2014년 2월 1일부터 10일까지 총 960개의 에너지 소비량 데이터이다.




Fig. 8. Training data using experiment.

그림 8. 실험에 사용될 학습 데이터

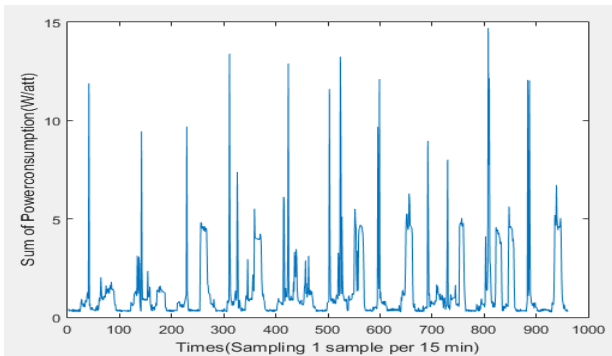


Fig. 9. Test data using experiment.  
그림 9. 실험에 이용한 테스트 데이터

### 2. 입력 데이터의 형태

그림 8을 보았을 때 에너지 소비량 데이터의 주기성이 일부 나타난다. 하지만 특정 요인에 의해 비주기성 특징도 가진다. CNN알고리즘의 특징 추출 방법을 이용하기 위하여 2976x1 행렬의 데이터를 하루 기준 96개의 데이터 행으로 31x96 행렬의 데이터로 구성한다.

### 3. 실험 파라미터

본 연구에서 실험을 진행시 사용한 실험 파라미터는 time step, filter, kernel size, batch size, epoch 그리고 pool size이다. 본 연구에서는 특징을 추출하는 filter와 모델의 반복 학습 정도를 나타내는 epoch를 변화하여 실험을 진행한다.

time step은 시계열 데이터를 모델의 입력에 맞게 데이터 세트를 구조화하는 과정에서 데이터 구성 시 사용하는 파라미터이다. time step의 크기에 따라 입력 데이터의 주기적, 비주기적 특성이 달라진다. 본 연구에서는 입력 데이터에 대한 time step을 하루 단위인 96으로 설정한다.

kernel은 CNN알고리즘의 입력 데이터의 특징을 찾아내는 공용 파라미터이다. kernel의 개수는 CNN 알고리즘의 입력 데이터를 kernel이 지정된 값만큼 순회하며 feature map을 만들어내는 작업을 한다. kernel size는 kernel이 지정된 값만큼 순회할 때 순회하는 간격을 말한다. 실험적으로 kernel의 개수는 2와 128로 설정하였고 kernel size는 4로 설정하였다.

pool size는 CNN알고리즘의 Pooling계층에 들어간 입력 데이터 행렬의 크기를 줄여주며 데이터의 특징을 추출할 때, 해당 특정 데이터의 특징을 강조하는 파라미터이다.

학습데이터의 불규칙 패턴을 추출하기 위해 CNN 계층의 출력인 feature map의 데이터를 줄여 주기 위해 pool size를 2로 설정하였다.

epoch는 모든 학습 데이터를 몇 번 반복 학습할 것인지 정하는 파라미터이다. 같은 데이터를 반복 학습 시킨다면 성능이 올라가는 경향이 있다. 본 연구에서는 epoch 수를 성능에 따른 변수로 사용하였다.

### 4. 실험결과

그림 10부터 그림 15까지는 1D-ConvBLSTM알고리즘의 kernel의 개수가 128일 때, epoch의 변화에 따른 실험 결과이다. 그림 16부터 그림 21까지는 1D-ConvBLSTM알고리즘의 kernel의 개수가 2일 때, epoch의 변화에 따른 실험 결과이다.

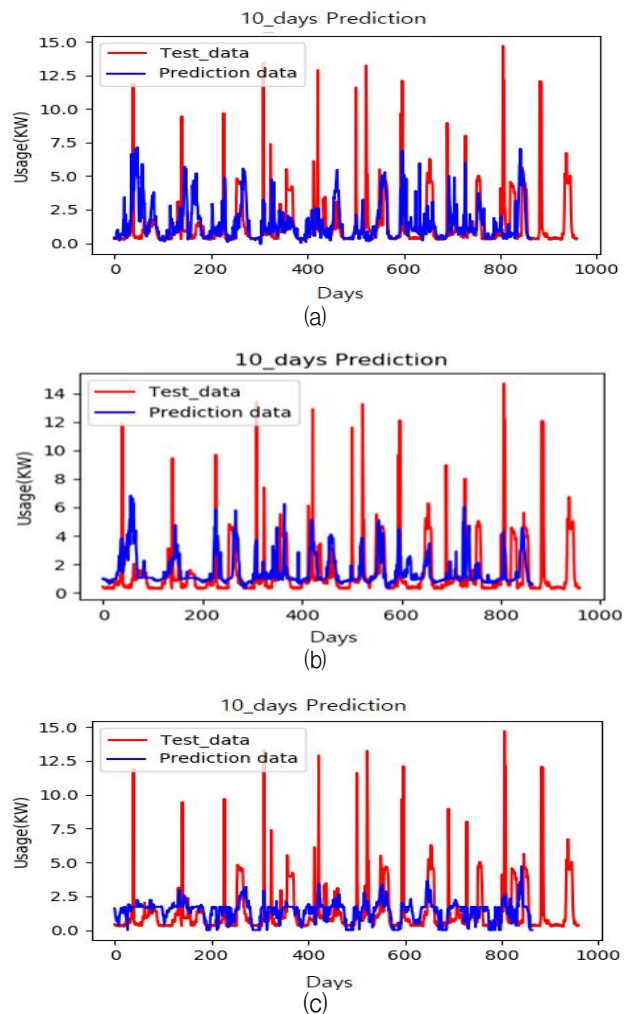


Fig. 12. Result of simulation at the number of kernel: 128 and (a) epoch: 5 (b) epoch: 20 (c) epoch: 40.  
그림 12. (a) epoch: 5 (b) epoch: 20 (c) epoch 40이고 kernel의 개수가 128일 때 시뮬레이션 결과

Table 1. Parameters of experiments.

표 1. 실험 파라미터

Parameters	Value
time step	96
number of kernel	2, 128
kernel ize	4
pool size	2
epoch	5,20,40

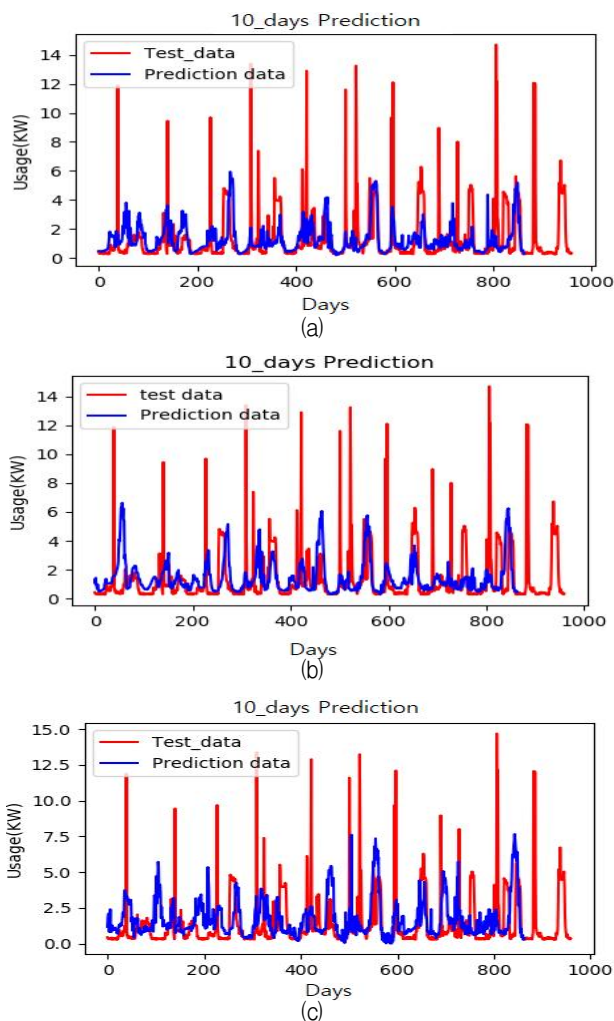


Fig. 15. Result of simulation at the number of kernel: 2 and (a) epoch: 5 (b) epoch: 20 (c) epoch: 40.

그림 15. (a) epoch: 5 (b) epoch: 20 (c) epoch 40이고 kernel의 개수가 2일 때 시뮬레이션 결과

위의 실험결과는 kernel의 개수와 epoch의 변화에 따른 시뮬레이션 결과를 보여준다. kernel의 개수가 128개일 때 epoch의 값이 5에서 모델의 학습 성능이 잘 검출되는 것이 나타난다. 하지만 epoch의 값이 20에서 40으로 증가함에 따라 모델이 과적

합에 빠지는 과정을 보여준다. kernel의 개수가 2개 일 때 epoch가 증가함에 따라 과적합에 빠지지 않는 경향을 보인다. 이러한 결과를 토대로 kernel의 개수와 epoch가 과적합을 발생시키는 요인으로 분석되고 최적의 예측성능을 도출하기 위해서 최적의 kernel의 개수와 epoch를 찾아야한다.

### III. 결론

본 논문에서는 CNN알고리즘과 BLSTM알고리즘을 기반으로 에너지 소비량 예측 분야에서 에너지 수요예측 모델을 제안했고 에너지 소비량 데이터를 기반으로 시뮬레이션을 진행했다. 실험 결과에 나타나듯이 본 논문에서 제안한 학습모델은 기존의 예측 알고리즘 학습보다 적은 수의 반복 학습을 통하여 테스트 데이터를 예측하였다. 또한, 1D-ConvBLSTM의 수요예측에 영향을 주는 변수들을 분석한 결과, 가장 성능이 좋게 나오는 실험 환경과 최적화 과정에서 과적합이 잘 일어나는 특정 변수를 파악하였다. 데이터를 학습시킬 때 기존의 예측 알고리즘보다 작은 반복학습으로 최적화 모델을 빨리 찾을 수 있었다.

최적화된 모델을 찾기 위해 모델의 학습 변수들과 데이터 세트를 조정하는 것에 대한 최적의 방법론이 아직 정의되어 있지 않다. 그러므로 최적화된 모델을 찾기 위한 방법론은 앞으로 연구가 진행되어야 한다.

### References

[1] F. Milletari, N. Navab and S. Ahmad, "V-Net: Fully convolutional neural networks for volumetric medical image segmentation," in *Proc of the 2016 Fourth International Conference on 3D Vision (3DV)*, Stanford, CA, USA, pp. 25-28, 2016. DOI: 10.1109/3DV.2016.79

[2] A. Kumar and Gerhard P. Hancke, "An energy-efficient smart comfort-sensing system based on the ieeec 1451 standard for green buildings," *IEEE Sensors*, vol. 14, no. 12, pp. 4245-4251, 2014. DOI: 10.1109/JSEN.2014.2356651

[3] J. Dequaire, P. Ondruska, D. Rao, D. wang

and I. posner, "Deep tracking in the wild: End-to-end tracking using recurrent neural networks," *The International Journal of Robotics Research*, vol. 37, no. 4, pp. 492–512, 2018.

DOI: 10.1177/0278364917710543

[4] M. O. Mario, "Human activity recognition based on single sensor square HV acceleration images and convolutional neural networks," *IEEE Sensors*, vol. 19, no. 4, pp. 1487–1498, 2018.

DOI: 10.1109/JSEN.2018.2882943

[5] D. Jeong, M. Baek and S. Lee, "Long-term prediction of vehicle trajectory based on a deep neural network," in *Proc. of the 2017 International Conference on Information and Communication Technology Convergence (ICTC)*, Jeju, South Korea, pp. 725–727, 2017.

DOI: 10.1109/ICTC.2017.8190764

[6] A. Tokgoz and G. Unal, "A RNN based time series approach for forecasting turkish electricity load," in *Proc. of the 2018 26<sup>th</sup> Signal Processing and Communications Applications Conference(SIU)*, Izmir, Turkey, 2018. DOI: 10.1109/SIU.2018.8404313

[7] Z. Chen, Y. Liu and S. Liu, "Mechanical state prediction based on LSTM neural network," in *Proc. of the 2017 36<sup>th</sup> Chinese Control Conference (CCC)*, Dalian, China, pp. 3876–3881, 2018.

DOI: 10.23919/ChiCC.2017.8027963

[8] R. FukuoKa, H. Suzuki, T. Kitajima, A. Kuwahara and T. Yasuno, "Wind speed prediction model using LSTM and 1D-CNN," *J-STAGE*, vol. 22, no. 4, pp. 207–210, 2018.

DOI: 10.2299/jsp.22.207

[9] K. A. Althelaya, E. M. Alfay and S. Mohammed, "Evalutaion of bidirectional LSTM for short-and long-term stock market prediction," in *Proc. of the 2018 9<sup>th</sup> International Conference on Information and Communication Systems(ICICS)*, Irbid, Jordan, pp. 151–156, 2018.

DOI: 10.1109/IACS.2018.8355458

[10] D. Niu, Z. Xia, Y. Liu, T. Cai and Y. Zhan, "Alstm: Adaptiv LSTM for durative Sequential data," in *Proc. of the 2018 30<sup>th</sup> International Conference on Tools with Artificial Intelligence*

(ICTAI), Volos, Greece, pp. 151–157, 2018.

DOI: 10.1109/ICTAI.2018.00032

[11] A. Graves, N. Jaitly and A. R. Mohamed, "Hybrid speech recognition with deep bidirectional LSTM," in *Proc. of the 2013 IEEE Workshop on Automatic Speech Recognition and Understanding*, Olomouc, Czech Repulic, pp. 273–278, 2013.

DOI: 10.1109/ASRU.2013.6707742

[12] Y. H. Chen, T. Krishna, J. S. Emer and V. Sze, "Eyeriss: An energy-efficient reconfigurable accelerator for deep convolutional neural networks," *IEEE Journal of Solid-State Circuits*, vol. 52, no. 1, pp. 127–138, 2017.

DOI: 10.1109/JSSC.2016.2616357

[13] F. J. Ordóñez and D. Roggen, "Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition," *Sensors*, pp. 3–9, 2016. DOI: 10.3390/s16010115

[14] T. D. Do, M. T. Duong, Q. V Dang and M. H. Le, "Real-time self-driving car navigation using deep neural network," in *Proc. of the 2018 4<sup>th</sup> International Conference on Green Technology and Sustainable Development(GTSD)*, pp. 7–12, 2018. DOI: 10.1109/GTSD.2018.8595590

[15] Y. Bengio, I. Goodfellow and A. Courville, *Deep learning*, MIT Press, 2016.

## BIOGRAPHY

**Ho Cheul Jung** (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.

**Sang Keun Oh** (Member)

2012 : M. Sc. degree in Electrical Engineering, Kwangwoon University.  
2007~present : Director in Dept of Power Electronics, PLASPO Company.

**Donggu Lee** (Member)

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

**Seung-Ho Song** (Member)

1999 : Ph. D. degree, Dept. of Electrical Engineering, Seoul National University.  
2006 : Assistant Professor, Div. of Electronics and Information, Chonbuk National University

2006~ present : Professor in Dept. of Electrical Engineering, Kwangwoon University.

**Soo Hyun Kim** (Member)

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

**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.

**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.

**Issac Sim** (Member)

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