

# 건물 예측 제어용 LSTM 기반 일사 예측 모델

전병기\* · 이경호\*\* · 김의종\*\*\*\*

\*인하대학교 대학원 건축공학과, 박사과정

\*\*한국에너지기술연구원, 책임연구원

\*\*\*인하대학교 건축공학과, 조교수

## Development of a Prediction Model of Solar Irradiances Using LSTM for Use in Building Predictive Control

Jeon Byung-Ki\* · Lee Kyung-Ho\*\* · Kim Eui-Jong\*\*\*\*

\*Ph.D. Candidate, Department of Architectural Engineering, Graduate School, Inha University

\*\*Principal Researcher, Department of Solar Thermal Convergence Lab, Korea Institute of Energy Research

\*\*\*Assistant Professor, Department of Architectural Engineering, Inha University

†Corresponding author: [ejkim@inha.ac.kr](mailto:ejkim@inha.ac.kr)

### Abstract

The purpose of the work is to develop a simple solar irradiance prediction model using a deep learning method, the LSTM (long term short term memory). Other than existing prediction models, the proposed one uses only the cloudiness among the information forecasted from the national meteorological forecast center. The future cloudiness is generally announced with four categories and for three-hour intervals. In this work, a daily irradiance pattern is used as an input vector to the LSTM together with that cloudiness information. The proposed model showed an error of 5% for learning and 30% for prediction. This level of error has lower influence on the load prediction in typical building cases.

**Keywords:** 일사예측(Prediction of solar irradiance), LSTM(Long-term short-term memory), 모델 예측제어(Model Predictive control), 딥러닝(Deep Neural Network)

### 기호설명

$E$  : 일사량 ( $W/m^2$ )

$n$  : 일조시간

### 하첨자

$M$  : 측정 데이터

$P$  : 예측 데이터



Journal of the Korean Solar Energy Society  
Vol.39, No.5, pp.41-52, October 2019  
<https://doi.org/10.7836/kses.2019.39.5.041>

pISSN : 1598-6411

eISSN : 2508-3562

Received: 14 October 2019

Revised: 24 October 2019

Accepted: 28 October 2019

Copyright © Korean Solar Energy Society

This is an Open-Access article distributed under the terms of the Creative Commons Attribution NonCommercial License which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

## 1. 서론

국내외 다양한 연구에서 건물에서 사용되는 에너지의 약 60%는 HVAC 운전이 필요하며<sup>1)</sup>, 따라서 건물의 열 및 공조시스템의 최적 제어로부터 에너지 효율을 높일 수 있다는 연구 결과를 제시하였다<sup>2)</sup>. 특히, 공조기의 효율적인 제어를 위해 모델을 사용하여 미리 시스템을 운전하여 최적 제어 전략을 수립하는 Model Predicted Control (MPC)와 관련한 연구는 지속적으로 증가하고 있다. 실제로 다양한 연구에서 건물 MPC를 통한 건물 에너지 소비 감소효과를 확인하였다<sup>3-5)</sup>. 다만 예측 제어의 성과는 건물 모델의 정확도에 기인하는데, MPC 적용을 위한 건물 모델에서는 시간별 기상 예보 정보를 필요로 한다<sup>6-8)</sup>. 여기서 기상 예보 정보는 한 시간 단위 혹은 그 이하의 외기온도와 일사량 데이터를 의미하는데 우리나라의 경우 기상청의 예보 시스템으로부터 외기온도 정보는 확보가 가능하지만 일사량의 경우 다음날의 시간별 일사량을 하루 전에 예보해주는 시스템은 전무하다. 선행 MPC 연구에서도 일사량을 직접 예측한 연구는 매우 드물며, 대부분 에너지 해석프로그램에서 제공하는 데이터를 활용하거나 일사예측 모델로부터 내일의 일사량이 예측 되었다고 가정한 후 연구를 진행하였다<sup>9)</sup>.

선행 일사 예측 모델을 조사해본 결과 일사예측 모델은 크게 물리모델과 데이터 기반모델의 형태로 개발되어져 왔다. 물리모델은 태양 기하학에 기반 해 관측 지역에서 측정된 운량을 포함한 일사량데이터와 기상 파라미터 사이의 적절한 경험적 상관 관계식을 구성하는 것이 일반적이다<sup>10)</sup>. Black은 한 지역에서 3년간 측정된 수평면 전 일사량, 운량 그리고 해당지역의 위도, 경도 사이의 관계를 분석해 일사량을 예측하는 모델을 개발하였고<sup>11)</sup>, 이후 Samimi<sup>12)</sup>는 같은 기상 파라미터를 사용해 이란지역의 17년간 누적된 기상데이터를 이용해 더욱 개선된 성능의 일사 예측 모델을 개발하였으나 언급된 모델은 오랜 기간 누적된 특정지역의 기상 데이터를 사용 하였기에 가용한 기상데이터가 부족한 지역에서 MPC를 위해 사용하기에는 어려움이 따른다. 이외에도 Premalatha<sup>13)</sup> 와 Valan and Daneshyar<sup>14)</sup> 등과 같이 습도, 바람, 강수 등 다양한 기상 파라미터와 장기간 누적된 데이터를 통해 지속적으로 일사예측 모델을 개발했으나, Neelamegam and Amirtham<sup>15)</sup>의 연구에 따르면 물리 기반 기상예측 모델은 특정 지역의 일사 특성을 반영하기 위해 오랜 기간 동안의 측정데이터를 요구하거나 기상예보로부터 확보하기 어려운 입력데이터를 사용해 지속적인 모델의 업데이트가 어려워 사용성이 부족한 것으로 알려져 있다.

일사예측 모델의 다른 방법론으로는 Artificial Neural Network (ANN)과 딥러닝 같은 머신러닝 기법을 활용하는 방식이 있으며 최근 관련 연구가 꾸준히 증가하고 있다. Lago et al.<sup>16)</sup>은 신경망 구조는 임의성이 큰 시계열 데이터의 학습 및 예측에 유리하다고 언급하였으며, Jiang<sup>17)</sup> 역시 경험적 물리 예측 모델 보다 ANN 예측 모델이 정확도가 높다고 보고하였다. 관련해서 Ahmad<sup>18)</sup>와 Solmaz et al.<sup>19)</sup> 등의 연구에서 각각 뉴질랜드와 터키의 다음날 시간별 일사량을 예측하는 모델을 개발하였으나, 외기온도, 상대습도, 강수량, 기압, 풍속 그리고 풍향 등 기상예보 시스템으로 쉽게 확보하기 어려운 데이터를 입력 값으로 사용하여 MPC 적용을 위한 일사예측 모델로 사용하기에는 어려움이 따른다. Qing and Niu<sup>20)</sup>은 현재의 일사 예측 모델은 모델을 활용하기 위해 많은 입력데이터를 활용해야 하는 문제점을 지적하면서 주거건물이나 소규모 상업건물에 MPC 적용을 위해 단순화된 일사예측 모델 제안하였으나, Table 1에서 알 수 있듯이 우리나라의 기상 예보 시스템은 다른 나라에 비해

제공되는 기상파라미터 종류와 운량 카테고리 등이 비교적 단순해 제안된 모델을 사용하기 어렵다.

**Table 1** Weather informations forecasted by countries<sup>21-24)</sup>

Information	Korea	UK	USA	Canada
Temperature	○	○	○	○
Dew-point temperature	X	X	○	X
Humidity	○	○	○	○ (Daily average)
Wind speed	○	○	○	○
Sky cover by categories	4	30	100	4
Time interval	3 hours	1 hour	1 hour	1 hour

선행연구에서도 알 수 있듯이 기존의 일사 예측 모델은 다양한 기상 파라미터나 해당 지역의 일사 특성을 반영하기 위해 장기간 측정데이터를 요구하기 때문에 데이터 확보가 어렵고 기존 누적 데이터가 없는 건물에서 MPC를 적용하기에는 어려움이 따른다. 따라서 본 연구에서는 장기간 누적된 데이터 없이도 특정 지역의 일사 특성을 반영하는 모델을 딥러닝을 통해 개발하고자 한다. 또한 기상청에서 확보 가능한 데이터인 운량만을 모델의 입력 값으로 사용하고 단순한 예보 간격을 고려해 연구의 실효성을 높이고자 한다.

## 2. 연구 방법 및 범위

앞서 언급했듯이 본 연구의 목적은 장기간 데이터가 확보가 어려운 지역에서 MPC 적용을 위해 활용 할 수 있는 단순화된 일사 예측 모델을 개발하는데 있다. 이를 위해 딥러닝 구조를 활용 하였고 일사량 예측을 위해 사용 된 입력데이터 종류는 기상청에서 쉽게 확보 할 수 있는 운량데이터만을 사용하였으며 연구에 사용된 기상데이터는 태양에너지 학회<sup>25)</sup>에서 제공하는 대한민국 주요 도시의 표준 기상데이터를 사용하였다. 표준 기상데이터는 서울, 광주, 대전, 대구, 울산, 부산 그리고 인천 등 7지역의 우리나라 주요 도시 기상 데이터를 제공한다. 이중 인천을 제외한 6개 지역의 일사 특성을 RNN 딥러닝 구조 중 LSTM 알고리즘을 통해 학습하고, 학습에 사용하지 않은 인천지역의 데이터를 예측함으로써 모델의 성능을 평가하였다. 다만, 표준기상데이터는 시간별로 상세한 운량 카테고리(0 ~ 100) 형태로 데이터가 제공되지만, 본 연구의 목적에 따라 기상청의 제한된 예보 시스템을 가정해 3시간 간격으로 데이터를 평균하여 사용 하였으며, 운량 카테고리 역시 매우 맑음(0 ~ 25), 맑음(26 ~ 50), 흐림(51 ~ 75), 매우 흐림(76 ~ 100) 등 4가지 카테고리로 단순화 하였다.

## 3. 딥러닝 기반 일사예측 모델 개발

### 3.1 LSTM 네트워크

대표적인 딥러닝 모델은 Convolution Neural Network (CNN)구조와 RNN (Recurrent Neural Network)

구조로 분류되며, CNN 구조는 그림 등 순서가 중요하지 않은 정보에 대한 학습 능력이 뛰어나고, RNN 구조는 시계열적 특성을 반영하기 유리한 딥러닝 구조이다<sup>26)</sup>. 본 연구의 예측 대상이 되는 일사량 데이터는 이전 시간대의 일사 발생 패턴이 일정부분 지속되는 시계열적 특성을 띄기 때문에 본 연구에서는 RNN 구조를 통해 일사 모델을 개발하고자 한다. 다만, RNN 구조는 많은 학습데이터를 처리 할 때 학습률이 갱신되지 않는 경사 감소 현상(Vanishing problem)<sup>27)</sup>이 발생하게 된다. LSTM 알고리즘은 Cell State라고 불리는 특징 층을 통해 이전의 가중치를 기억, 제거 여부를 결정해 경사감소 문제를 해결 하였다. 따라서 본 연구에서는 이러한 오류를 수정한 RNN 구조인 Long Short Term Memory Network (LSTM) 모델을 통해 학습을 진행하였다<sup>28)</sup>.

LSTM 모델은 MATLAB에서 제공하는 딥러닝 툴박스를 이용하였으며, 해당 구조는 학습 성능을 결정하는 다양한 환경 변수를 지정해주어야 한다. 먼저, MATLAB 에서는 학습을 진행하는 최적화 기법으로 Stochastic Gradient Descent (SGD) 알고리즘과 Adaptive Moment Estimation (ADAM) 알고리즘을 제공하고 있다. SGD 알고리즘은 확률적 경사 하강법으로 반복계산을 위한 충분한 작업 환경이 갖추어지지 않았을 때 학습에 소비하는 시간이 길어지는 단점이 있다고 알려져 있다<sup>29)</sup>. 반면 Adam 알고리즘은 유동적으로 학습률을 조절하여 단시간에 효율적으로 최적해를 찾는데 유리한 알고리즘이다<sup>30)</sup>. 현재 알려진 다양한 학습 알고리즘 중 모든 상황에서 항상 뛰어난 성능을 보이는 알고리즘은 없으나 본 연구의 목적은 MPC 적용을 위한 하루 단위 일사 예측을 반복적으로 수행해야 하므로 비교적 계산 속도가 빠른 Adam 알고리즘을 선택하였다. 학습 모델은 Hidden Layer와 Hidden Unit의 가중치를 조절하며 모델의 오차를 최소화 하는데 이때 Layer와 Unit을 구성하는데 정확한 지침이나 규칙은 정해져 있지 않으며 사용자의 경험에 의존해 결정되어 진다. 본 연구에서는 3개의 Hidden Layer를 사용하는 Deeper LSTM 모델을 구성하였으며 하나의 Layer당 300개의 Hidden Unit을 구성하였다. 이는 본 연구에서 사용하는 시뮬레이션 툴인 MATLAB에서 기본값으로 제공<sup>31)</sup>하는 250개보다 조금 많은 수치이다. 학습에 사용된 데이터는 정규화(normalization) 과정을 거쳐 학습결과가 발산하는 현상을 방지하였으며, 연산은 GPU(Graphics processing unit-GTX 1060 6 GB) 병렬 처리 기술을 사용해 진행하였다. 기타 학습 모델의 설정 값은 Table 2와 같으며 이는 MATLAB에서 제공하는 권장 값에 근거하여 결정하였다.

**Table 2** Parameters of the LSTM model

Opt. algorithm	Adam	Hidden layer	3
Initial Learn Rate	0.001	Hidden Unit	300 (×3)
Execution Environment	GPU	Max Epochs	800

### 3.2 일사예측 모델

앞서 언급했듯이 본 연구에서 제안되는 일사 예측 모델은 과거 일사량 발생 패턴을 LSTM 모델을 통해 학습, 예측을 진행하게 된다. 여기서 LSTM 모델은 입력데이터의 벡터 크기에 따라 모델의 성능이 달라지기 때문에

목적에 따라 적절한 벡터 크기를 정하는 것이 중요하다. 예를 들어 Fig. 1의 위쪽 그래프와 같이 1년의 일사량 전체를 단 하나의 벡터로 구성 할 경우 계절, 월 등 장기 예측 성능에서는 유리 할 수 있으나 학습 환경에 따라 일, 요일 등 짧은 기간의 예측 성능은 떨어 질 수 있다. 반면 Fig. 1 아래 그림처럼 벡터 크기를 일단위로 세분화 한다면 단기 일사 예측에 적합한 학습 모델을 구축 할 수 있다. 본 연구의 목적은 MPC 적용을 위한 일 단위 일사 예측 모델을 개발하는데 있으므로 본 연구에서는 Fig. 1의 아래 그림처럼 데이터를 하나의 벡터는 24개의 데이터로 구성되게 입력데이터를 분할하여 사용하였다.




Fig. 1 Example of data vectors used for learning

Fig. 2와 같이 모델의 입력 데이터는 운량(Day, Day+1), 수평면 전일사량(Day) 두 종류의 데이터만을 사용하였으며 학습 목표가 되는 출력데이터는 다음날의 수평면 전일사량(Day+1)으로 하여 전날의 일사 발생 패턴에 따라 다음날의 일사량을 예측하도록 모델을 설계 하였다. 기존 단순 학습기반 일사예측 모델은 시계열 패턴을 고려하지 않는 것이 일반적이거나 그림에서 보는 바처럼 제안한 모델은 전날의 일사량 전체 패턴과 이에 대응하는 운량 패턴 전체가 입력데이터로 고려되기 때문에 다양한 장점을 지닌다. 첫째 입력 값으로 전날의 일사패턴 전체를 사용하기 때문에 해당지역의 위치정보(위도) 및 시간(월, 분기) 정보가 별도로 필요하지 않다. 즉 다음날의 일사강도는 입력 값으로 사용되는 전날의 일사강도에 영향을 받는다. 둘째, 모델 입력 값이 단순하므로 다양한 지역의 가용한 누적 데이터를 학습에 이용할 수 있으며, 내일의 일사량 예측은 운량 예보와 오늘 대상지에서 측정된 데이터만을 사용하므로 장치 구현이 용이하다. 제안된 모델의 학습 과정과 입출력 행렬 크기는 Fig. 2에 도식화 하였다.

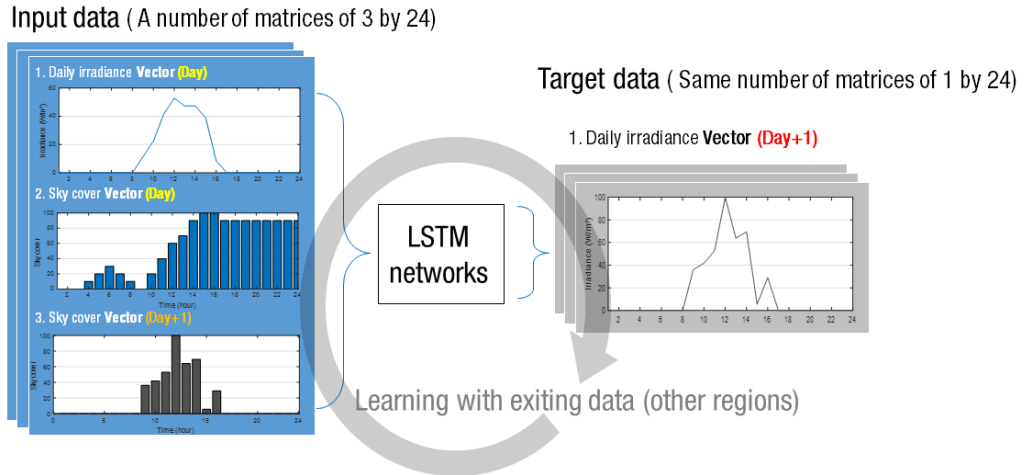


Fig. 2 I/O of the proposed LSTM model for the learning step

## 4. 시뮬레이션 결과 및 분석

### 4.1 시뮬레이션 개요

연구의 목적은 누적된 일사 측정데이터가 부족한 상황에서 활용 할 수 있는 일사예측 모델을 구축하는데 있으므로 연구의 범위에서 언급했듯이 태양에너지학회 에서 제공하는 7개 지역 중 인천 지역을 제외한 6개 지역 을 학습데이터로 활용하고 학습에 사용되지 않은 인천 지역의 일사량을 일단위로 예측하여 오차를 비교하는 방식으로 모델의 성능을 평가 할 예정이다. 단, 모델의 입력데이터는 하루단위 데이터 통신을 가정하여 실제 측정 된 일사량과 예보 운량이 24시간마다 업데이트됨을 가정하여 하루단위로 모델에 예보 데이터를 갱신하였다. 기상청 예보는 100% 정확하다는 가정하에 제안한 모델의 예측 오차만을 평가하는 데 중점을 두었다. 따라서 기상청 예보 성능에 따라 최종 예측 성능을 달라질 수 있다. 모델의 예측결과는 Root Mean Square Error (RMSE), Normalized RMSE (NRMSE)를 통해 평가하였으며 이는 식(1), (2)와 같다. 여기서 NRMSE는 일사량과 같이 최대, 최소값의 편차가 큰 데이터를 평가할 때 주로 사용되는 지표이다<sup>32)</sup>. 또한, 일사량의 평가를 비율로 하게 될 경우 분모가 되는 측정값의 범위에 따라 오차율이 크게 변동하게 된다. Kim et al.<sup>33)</sup>은 대전지역의 일사량을 예측하는 모델을 개발하였는데, 평가에 있어 불확도를 줄이고 모델의 객관적인 평가를 위해 일사량이 발생하는 비율이 적은 시간을 제외하고 9시부터 17시까지를 주요 일조 시간으로 가정 후 모델을 평가하였다. 본 연구에서도 연간 일사 발생 비율이 낮은 시간대를 제외하고 연간 일사 발생 횟수가 50%가 넘는 시간대인 8시부터 18시 까지를 주요 일조시간으로 선정하고 모델의 평가를 진행하였다. 인천지역 표준기상데이터에 따른 시간에 따른 연간 일사발생 횟수는 Table 3과 같다. 대상 지역의 하루단위 일사가 발생하는 시간의 데이터에 대해서만 오차를 평가하였다.

**Table 3** Annual occurrence of solar irradiances over time periods


Time	1-5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20-24
Event	0	42	112	264	343	353	358	357	360	360	356	344	286	184	85	0
Percent (%)	0	11	30	72	94	97	98	98	99	99	98	95	79	50	23	0

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_{P,i} - E_{M,i})^2}{n}} \tag{1}$$

$$NRMSE = \frac{RMSE}{E_{M,max} - E_{M,min}} \tag{2}$$

### 4.2 일사예측 모델 결과

제안된 일사 모델은 6개 지역의 일사 발생 패턴의 관계를 가장 잘 묘사하는 뉴런과 레이어 사이의 연결강도를 통해 모델을 구축한다. 여기서 학습 데이터가 되는 6개 지역의 일사 발생 패턴을 비슷하게 묘사하는 모델을 구축하게 된다면 학습에 사용되지 않은 데이터인 인천지역의 일사량 발생 패턴 예측 오차가 줄어들 것으로 기대할 수 있다. 따라서 예측에 앞서 먼저 모델의 학습 성능을 분석하였고 그 결과는 Fig. 3과 같다. 산점도는 점들이 대각선에 분포 할수록 모델이 정확함을 의미하는데 몇몇의 이상치를 제외하면 대부분의 점들이 회색 대각선 근처에 분포하였으며 RMSE 5.7 W/m<sup>2</sup>, NRMSE 3.9%의 오차만을 보였다.



**Fig. 3** Learning performance :total horizontal irradiance prediction model

Fig. 4는 제안된 모델을 통해 예측 대상 지역이었던 인천지역의 연간 일사량 예측 결과를 나타내며 RMSE 47 W/m<sup>2</sup>, NRMSE 28.9% 수준을 보였으며 이는 3.9%의 오차만을 보인 학습성능에 비해서는 오차가 상승한 결과이다. 해당 오차는 건물에너지 해석 프로그램인 EnergyPlus 단독 주거 건물 템플릿에서 79.3 W/m<sup>2</sup>의 수평면 전일사량 오차는 약 2% 수준의 건물 부하 오차를 발생 시킨다는 Jeon et al.<sup>9)</sup>의 연구를 참고하면, 제안한 모델은 MPC 적용을 위해 충분히 사용이 가능할 것으로 보여진다. 또한 테스트 환경이 다르기 때문에 객관적인 비교는 어려우나 제안된 모델의 예측 성능 RMSE 47 W/m<sup>2</sup>는 선행 연구에서 연구의 목표가 같았던 Qing and Niu 모델보다 더욱 단순한 모델임에도 낮은 RMSE 오차(Qing and Niu-76 W/m<sup>2</sup>)를 보였다.




Fig. 4 Predicting performance : total horizontal irradiance prediction model

또한, Fig. 5는 임의의 구간의 예측 성능을 나타내는데 제안된 모델은 전날의 일사 패턴을 학습-예측에 사용하기 때문에 모델 구축에 일사량과 운량 파라미터만을 사용했음에도 2881-2905, 2929-2953, 3121-3145 구간 등 매우 흐림의 동일한 운량 카테고리에서도 각기 다른 수준의 일사 발생 패턴을 유사하게 묘사할 수 있었다. 즉 동일한 운량 예측, 동일한 시간대에서도 서로 다른 일사량 패턴을 예측하였고 이 예측 값은 측정 값의 변화 패턴과 유사하였다. 이는 물리 모델로는 묘사하기 매우 어려우며, 기존 신경망 구조에서는 해당 구간을 묘사하기 위해서는 다수의 입력 파라미터를 사용하여 모델을 구축할 때만 가능한 결과이기도 하다.

모델의 오차 원인을 분석하면 다음과 같다. 먼저 본 연구에서는 기상청의 단순화된 예보 시스템과 동일한 조건으로 다음날의 운량예보가 3시간 단위로 이루어짐을 가정해 모델을 구축하였다. Fig. 6은 우리나라 기상예보가 Table 1의 다른나라와 같이 1시간 단위로 운량을 예보 하게 됨을 가정하여 동일한 학습조건에서 시뮬레이션한 결과이다. 그래프에서 알 수 있듯이 임의의 구간에서 모델의 성능이 개선되며 RMSE 오차는 43.49 W/m<sup>2</sup>로 소폭 개선됨을 확인 할 수 있었다. 또한 현재 운량 카테고리는 4개로 매우 한정적이지만 향후 더욱 세분화된 운량 카테고리 예보가 제공된다면 모델의 오차는 더욱 줄어들 것으로 판단된다.






Fig. 5 Sequenced solar irradiance prediction (12 days)




Fig. 6 Sequenced solar irradiance prediction (one week)

다음으로 현재는 제공되는 데이터의 한계로 최대 6개 지역 데이터만 학습이 가능하지만 향후 학습에 사용 할 수 있는 데이터가 많아질수록 모델의 학습, 예측 성능은 개선 될 것으로 판단된다. 반증으로 Fig. 7은 제안되었던 예측모델보다 학습데이터가 적은 3개, 5개 지역으로 학습하였을 때 모델의 예측 성능을 나타내며 각각 NRMSE 31%, 30%의 오차를 보이며 학습에 사용한 데이터가 많아질수록 모델의 오차가 줄어드는 것을 확인할 수 있었다. 현재는 모든 모델이 동일한 신경망 환경에서 학습되었기 때문에 데이터 양이 적은 3 Region 모델이 미소하게 우수한 학습 성능을 보였으나, 향후 데이터 개수에 따라 Hidden layer 성능을 강화 할 시 모델의 학습 오차는 더욱 줄어들 것으로 판단된다. 그러나 전반적으로 학습 데이터 양을 늘릴수록 예측 성능은 개선되었다. 제안된 다양한 테스트 환경의 일사예측 모델의 학습, 예측 성능은 Table 4에 정리하였다.




Fig. 7 Solar irradiance prediction using LSTM (3 vs. 5 regions)

Table 4 Learning and prediction performance of LSTM models according to numbers of input regions

Model		Phase	RMSE (W/m <sup>2</sup> )	NRMSE (%)
Current meteorological prediction (3 hours)	3-Region model	Learning	2.52	1.72
		Prediction	53.94	31.3
	5-Region model	Learning	3.97	2.71
		Prediction	53.52	30.0
	6-Region model	Learning	5.77	3.94
		Prediction	47.75	28.93
One-hour basis	6-Region model	Learning	1.18	0.81
		Prediction	43.49	24.96

## 5. 결론

본 연구에서는 건물의 예측제어에 필요한 미래 입력 데이터인 일사량을 예측하기 위해 딥러닝 모델 기반 학습 모델을 제안하였다. 제안한 모델은 우리나라 기상 예보시스템에서 제공하는 가용 데이터만을 사용하였기 때문에, 기존 연구와 달리 장기간 누적된 해당지역 일사데이터 요구하지 않아 모델의 활용성과 실효성 측면에서 유리하다. 예측모델은 딥러닝 LSTM 알고리즘을 사용해 구축되었으며 태양에너지학회에서 제공하는 7개의 표준 기상데이터 중 6개 지역의 데이터만 학습에 진행하고 학습하지 않은 지역의 일사량을 예측 사용하여 모델의 성능을 검증하였다. 모델의 학습성능은 RMSE 5.77 W/m<sup>2</sup> (NRMSE 3.9%)로 매우 우수 하였으나 예측 성능은 47.75 W/m<sup>2</sup> (NRMSE 28%) 수준의 오차를 보였다. 이는 선행연구의 건물부하 모델에 적용 하였을 때 2%수준에 해당하는 오차로 예측 제어용 입력데이터로 활용할 수 있을것으로 판단된다. 일사량 예측을 위해 사용된 파라미터는 예보된 운량 뿐 임에도 제안 모델은 타지역의 일사량 데이터를 학습에 포함시키는 새로운 방법을 제안하고, 전날의 일사 패턴을 학습해 다양한 상황의 일사 변동 패턴을 묘사하며 MPC 적용에 있어 신뢰할 수 있

는 예측 결과를 제공하였다. 본 연구는 MPC적용을 위한 단순 기상예측 모델의 초기연구로 향후 기상청에서 좀 더 상세한 예측 정보를 제공하고, 모델을 학습 할 수 있는 일사 데이터가 더욱 풍부해진다면 모델의 오차는 개선 될 것으로 판단된다.

## 후기

본 연구는 한국에너지기술연구원의 주요사업(B9-8109)을 재원으로 수행한 연구과제의 결과입니다.

## REFERENCES

1. Zhuang, J., Chen, Y., and Chen, X. A., New Simplified Modeling Method for Model Predictive Control in a Medium-Sized Commercial Building: A Case Study. *Build. Environ*, Vol. 127, pp. 1-12, 2018.
2. Henze, G. P., Felsmann, C., and Knabe, G., Evaluation of Optimal Control for Active and Passive Building Thermal Storage. *International Journal of Thermal Sciences*, Vol. 43, pp. 173-183, 2004.
3. Ferreira, P. M., Ruano, A. E., Silva, S., and Conceicao, E. Z. E., Neural Networks Based Predictive Control for Thermal Comfort and Energy Savings in Public Buildings. *Energy and Buildings*, Vol. 55, pp. 238-251, 2012.
4. Huang, H., Chen, L., and Hu, E., A New Model Predictive Control Scheme for Energy and Cost Savings in Commercial Buildings: An Airport Terminal Building Case Study. *Building and Environment*, Vol. 89, pp. 203-216.
5. Kusiak, A., Li, M., and Tang, F., Modeling and Optimization of HVAC Energy Consumption. *Applied Energy*, Vol. 87, No.10, pp. 3092-3102, 2010.
6. Nguyen, T. T., Yoo, H. J., and Kim, H. M., Analyzing the Impacts of System Parameters on MPC-based Frequency Control for a Stand-alone Microgrid. *Energies*, Vol. 10, No. 4, p. 417, 2017.
7. Afram, A. and Janabi-Sharifi, F., Theory and Applications of HVAC Control Systems-A Review of Model Predictive Control (MPC). *Building and Environment*, Vol. 72, pp. 343-355.
8. Khanmirza, E., Esmaeilzadeh, A., and Markazi, A. H. D., Predictive Control of a Building Hybrid Heating System for Energy Cost Reduction. *Applied Soft Computing*, Vol. 46, pp. 407-423, 2016.
9. Jeon, B. K., Kim, E. J., Shin, Y., and Lee, K. H., Learning-Based Predictive Building Energy Model Using Weather Forecasts for Optimal Control of Domestic Energy Systems. *Sustainability*, Vol. 11, No. 1, pp. 1-16, 2018.
10. Premalatha, N. and Valan Arasu, A., Prediction of Solar Radiation for Solar Systems by Using ANN Models with Different Back Propagation Algorithms. *Journal of Applied Research and Technology*, Vol. 14, No. 3, pp. 206-214, 2016.
11. Black, J. N., The Distribution of Solar Radiation Over the Earth's Surface. *Archiv für Meteorologie, Geophysik und Bioklimatologie, Serie B*, Vol. 7, No. 2, pp. 165-189, 1956.
12. Samimi, J., Estimation of Height-dependent Solar Irradiation and Application to the Solar Climate of Iran. *Solar Energy*, Vol. 52, No. 5, pp. 401-409, 1994.
13. Paltridge, G. W. and Proctor, D., Monthly Mean Solar Radiation Statistics for Australia. *Solar Energy*, Vol. 18, No. 3, pp. 235-243, 1976.
14. Daneshyar, M., Solar Radiation Statistics for Iran. *Sol. Energy;(United States)*, Vol. 21, No. 4, 1978.
15. Premalatha, N. and Valan Arasu, A., Prediction of Solar Radiation for Solar Systems by Using ANN Models

- with Different Back Propagation Algorithms. *Journal of Applied Research and Technology*, Vol. 14, No. 3, pp. 206-214, 2016.
16. Lago, J., De Ridder, F., and De Schutter, B., Forecasting Spot Electricity Prices: Deep Learning Approaches and Empirical Comparison of Traditional Algorithms, *Applied Energy*, Vol. 221, pp. 386-405, 2018.
  17. Jiang, Y., Computation of Monthly Mean Daily Global Solar Radiation in China Using Artificial Neural Networks and Comparison with Other Empirical Models, *Energy*, Vol. 34, No. 9, pp. 1276-1283, 2009.
  18. Ahmad, A., Anderson, T. N., and Lie, T. T., Hourly global solar irradiation forecasting for New Zealand, *Solar Energy*, Vol. 122, pp. 1398-1408, 2015.
  19. Solmaz, O., Kahramanli, H., Kahraman, A., and Ozgoren, M., Prediction of Daily Solar Radiation Using ANNs for Selected Provinces in Turkey. In *International Scientific Conference*, pp. 450-456, November, 2010.
  20. Qing, X. and Niu, Y., Hourly day-ahead Solar Irradiance Prediction Using Weather Forecasts by LSTM. *Energy*, Vol. 148, pp. 461-468, 2018.
  21. <http://www.kma.go.kr/>, Korea Official Meteorological Agency.
  22. <https://www.metoffice.gov.uk/>, UK Official Meteorological Agency.
  23. <https://www.weather.gov/>, United States Official Meteorological Agency.
  24. <https://weather.gc.ca/>, Canadian Official Meteorological Agency.
  25. <http://www.kses.re.kr/>, The Korean Solar Energy Society.
  26. Lee, L. J., A Study on Fundamental and Application of CNN and RNN. *Broadcasting and Media Magazine*, Vol. 22, No. 1, pp. 87-95, 2017.
  27. Saito, G., *Deep Learning from Scratch*, Hanbit Media Inc, 2017.
  28. Baccouche, M., Mamalet, F., Wolf, C., Garcia, C., and Baskurt, A., Sequential Deep Learning for Human Action Recognition. In *International Workshop on Human Behavior Understanding*, Springer, Berlin, Heidelberg, pp. 29-39, November, 2011.
  29. Kinga, D. and Adam, J. B., A Method for Stochastic Optimization. In *International Conference on Learning Representations(ICLR)*, Vol. 5, 2015.
  30. Kong, D. S., Kwak, Y. H., and Huh, J. H., Artificial Neural Network Based Energy Demand Prediction for the Urban District Energy Planning. *Journal of the Architectural Institute of Korea*, Vol. 26, No. 2, pp. 221-230, 2010.
  31. Documentation, M., The MathWorks Inc, 2005.
  32. Gutierrez-Corea, F. V., Manso-Callejo, M. A., Moreno-Regidor, M. P., and Manrique-Sancho, M. T., "Forecasting Short-term Solar Irradiance Based on Artificial Neural Networks and Data from Neighboring Meteorological Stations." *Solar Energy*, Vol. 134, pp. 119-131, 2016.
  33. Kim, T. H., Yoo, S. Y., Han, K. H., Kang, H. C., and Yoon, H. I., A Study on Solar Radiation Model for Prediction of Solar Insolation. *The Korean Society of Mechanical Engineers*, pp. 670-675, 2013.