

# 기상정보를 활용한 LSTM 기반 태양광 발전량 예측 기법

김 용 수\*, 이 상 현\*, 김 호 원<sup>o</sup>

## Prediction Method of Photovoltaic Power Generation Based on LSTM Using Weather Information

Yongsu Kim\*, Sanghyun Lee\*, Howon Kim<sup>o</sup>

요 약

최근 화석연료 고갈 및 지구 온난화 문제가 대두되고 있으며, 이러한 문제를 해결하기 위해 환경 친화적이며 무한한 에너지를 가지는 태양광 에너지가 주목받고 있다. 태양광 발전 관리에 있어 효율적인 운영과 경제성 향상을 위해서는 정확한 태양광 발전량 예측이 필요하다. 본 연구에서는 시계열 데이터 분석 및 예측에 효과적인 딥러닝 기법 중 하나인 LSTM(Long Short-Term Memory)과 기온, 습도, 전운량, 자외선 지수 등의 기상정보를 통해 시간 단위의 태양광 발전량을 예측하는 기법을 제안한다. 제안하는 기법은 정해진 시점이 아닌 원하는 구간의 발전량 예측을 하여 가용성이 높으며, 태양광 발전량과 가장 밀접한 관계에 있는 일사량을 먼저 예측함으로써 발전량 예측 정확도를 높였다. 제안하는 기법의 LSTM 기반 예측 모델의 발전량 예측 결과 오차율인 MAE와 NMAE는 각각 1.5424와 0.0454이며, DNN 기반 예측 모델의 MAE와 NMAE인 1.9347, 0.0569에 비해 오차율이 낮은 것을 확인하였다.

**Key Words** : Solar Photovoltaic Power Prediction, Insolation Prediction, Weather Information, Deep Learning, LSTM

ABSTRACT

Recently, fossil fuel depletion and global warming problems are emerging. To solve these problems, solar energy comes into the limelight which is eco-friendly and has unlimited energy sources. For efficient operation and improving economic efficiency in managing solar power, accurate prediction of photovoltaic power generation is needed. This study proposes a technique to predict solar power in time units through Long Short-Term Memory (LSTM) and weather information such as temperature, humidity, cloud coverage, and ultraviolet index. The proposed technique is highly available by predicting the solar power generation of the desired section instead of the fixed time point, and the accuracy of the solar power generation prediction is increased by predicting insolation that is most closely related to photovoltaic power. The power generation prediction results of the LSTM based forecast model show that the error rates of MAE and NMAE are 1.5424 and 0.0454, respectively, and the error rates are lower than those of MAE and NMAE of the DNN based forecast model, 1.9347, 0.0569.

※ 이 논문은 국토교통부의 스마트시티 혁신인재육성사업으로 지원되었습니다.

♦ First Author : Department of Computer Science Engineering, Pusan National Univ., dkgogog0329@gmail.com, 학생회원

o Corresponding Author : Department of Computer Science Engineering, Pusan National Univ., howonkim@gmail.com, 종신회원

\* Department of Computer Science Engineering, Pusan National Univ., jdsd2233@gmail.com

논문번호 : 201910-249-C-RU, Received October 23, 2019; Revised November 13, 2019; Accepted November 19, 2019

## I. 서 론

최근 10년간 우리나라의 에너지 소비는 매년 10%라는 세계 최고의 증가율을 기록하고 있으며, 온실가스 배출량 증가율 역시 세계 1위를 기록하고 있다<sup>[1]</sup>. 이에 따라 화석연료 고갈 및 지구 온난화 문제가 대두되고 있으며, 이러한 문제를 해결하기 위해 환경 친화적이며 무한한 에너지를 가지는 신재생에너지가 주목받고 있다. 태양광 발전은 신재생에너지 분야에서 가장 많은 비중을 차지하고 있으며, 화석 연료를 대체할 수단으로 떠오르고 있다. 하지만 태양광 발전은 외부 조건에 따라 변동이 심하기 때문에 기존의 화석 연료를 통한 전력 수급을 적절히 조절할 필요가 있다. 이에 따라 기존의 전력 발전과 태양광 발전 사이의 전력 생산 균형을 맞추고 전력 공급 계획을 효율적으로 세우기 위해 정확한 태양광 발전량 예측이 필요하다.

태양광 발전량은 기상 조건과 설비 상태 등 다양한 요소에 영향을 받기 때문에 정확한 예측을 하는 것이 어렵다. 이에 따라 복잡한 변화를 보이는 데이터를 효과적으로 분석하고 예측할 수 있는 머신러닝 및 딥러닝 기법을 적용하여 태양광 발전량을 예측하는 연구가 활발히 진행되고 있다. Sharma<sup>[2]</sup> 등은 SVM(Support Vector Machine)을 이용하여 태양광 발전량 예측을 하였으며, 단일 차원 벡터에 비해 약 27%의 성능 향상을 하였다. 해당 연구는 기준 시점으로부터 3시간 이후의 태양광 발전량을 예측한 것으로써, 3시간 보다 이후의 시점이나 어떤 구간에 대한 발전량을 예측하지 못하는 단점이 있다. 이승민<sup>[3]</sup> 등은 신경망, SVM, 딥러닝을 이용하여 태양광 발전량 예측 실험을 진행하였으며, 일별 발전량과 기상정보 데이터를 학습하여 하루 단위의 발전량을 예측하였다. 해당 연구에서 이용한 예측 기법 중 여러 개의 은닉층을 가지는 심층 신경망이 가장 높은 예측 정확도를 보였다. Jidong<sup>[4]</sup> 등은 FOS-ELM(extreme learning machine with forgetting mechanism) 알고리즘을 이용하여 단기간의 태양광 발전량을 예측하였다. 해당 연구는 과거 기상정보와 과거 발전량 데이터를 이용하여 미래의 발전량을 예측하는 프로세스를 적용하였다. 배국열<sup>[5]</sup> 등은 기계학습 기법 중 ANN과 SVM을 이용하여 태양광 발전량을 예측하였다. 해당 연구는 데이터 클러스터링, 학습 및 테스트 단계를 통해 발전량 예측을 진행하였으며, 기상 입력변수와 관련하여 날씨 예측오차의 태양광 출력 예측 정확도에 끼치는 영향을 분석하였다. Pedro<sup>[6]</sup> 등은 통계적 시계열 분석 기법인 ARIMA 및 K-nearest neighbors(KNN), ANN

기반의 모델 등을 이용하여 태양광 발전량 예측을 진행하여 비교 및 평가하였다. 이외에도 RBF Network, ARMAX, MAR, ANN, DNN 등 다양한 머신러닝 기법을 적용하여 태양광 발전량 예측을 진행하고 비교 및 분석한 연구가 진행되었다<sup>[7-11]</sup>.

하지만 이러한 연구들은 특정 시점만의 발전량을 예측하거나 시간 단위의 세밀한 발전량을 예측하지 못하는 등의 단점이 있다. 본 연구에서는 딥러닝 기법 중 시계열 데이터 분석 및 예측에 효과적인 LSTM(Long Short-Term Memory)를 이용하여 기온, 습도, 전운량, 자외선 지수 등의 기상예보 데이터를 통해 시간 단위의 태양광 발전량을 높은 정확도로 예측하는 기법을 제안한다. 본 논문의 구성은 다음과 같다. 2장에서는 발전량과 기상정보 간 상관관계 분석, 데이터 구성 및 전처리, 예측 모델 구성 방법에 대해 살펴본다. 3장에서는 제안하는 방법으로 태양광 발전량 예측 실험을 진행하여 성능을 평가하고, 4장에서는 실험 결과를 정리하고 차후 연구 방향을 소개하며 결론을 맺는다.

## II. 본 론

### 2.1 발전량과 기상정보 간 상관관계 분석

태양광 발전량은 기상 조건에 큰 영향을 받으며, 그 중 일사량과 가장 밀접한 관계가 있다. 본 연구에서는 시간 단위의 정밀한 발전량 예측을 위해 지역에 따른 시간 단위의 기상정보 데이터를 제공해주는 Dark Sky API<sup>[12]</sup>를 이용하였다. 국내 기상청 데이터는 특정 시간대에 결측값이 존재하는 문제가 있으며, 과거 기상정보 데이터와 기상예보 데이터의 종류가 다르기 때문에 과거 기상정보를 학습해도 기상예보를 통해 발전량을 예측하기 어렵다. 반면에 Dark Sky API는 원하는 지역의 위도 및 경도를 입력하여 결측값이 없는 완전한 기상정보 데이터를 제공받을 수 있으며, 과거 기상정보와 기상예보 데이터 종류가 같아 발전량 예측에 효과적이기 때문에 본 연구에서 사용하였다.

또한 태양광 발전량 데이터는 충남 지역 2곳의 발전소, 제주 지역 1곳의 발전소 데이터를 이용하였으며, 해당 데이터는 발전량뿐만 아니라 발전 설비가 받아들이는 일사량까지 포함한다. 본 연구의 실험을 위해 제공받은 발전소 데이터는 2019년 2월 9일부터 2019년 9월 30일까지의 데이터를 포함한다.

정확한 태양광 발전량 예측을 위해서는 발전량에 영향을 가장 많이 미치는 변수들을 파악해야 하며, 이를 위해 발전량과 기상정보 간 상관관계를 분석하여

표 1에 나타내었다. 상관 계수는 식 (1)의 Pearson correlation coefficient를 사용하였다.

$$\rho_{X,Y} = \frac{E[(X-\mu_X)(Y-\mu_Y)]}{\sigma_X\sigma_Y} \quad (1)$$

식 (1)에서  $\rho_{X,Y}$ 는 변수  $X$ 와  $Y$ 의 상관 계수,  $\sigma_X$ 와  $\sigma_Y$ 는 각각  $X$ 와  $Y$ 의 표준편차,  $\mu_X$ 와  $\mu_Y$ 는 각각  $X$ 와  $Y$ 의 평균,  $E$ 는 기댓값을 의미한다. 상관 계수의 절댓값이 1에 가까울수록 두 변수가 밀접한 관계에 있음을 나타낸다.

표 1. 발전량 및 일사량과 기상정보 간 상관관계  
Table 1. A correlation between solar photovoltaic power and weather factors including insolation.

| Weather factor | Correlation coefficient |            |
|----------------|-------------------------|------------|
|                | Power Generation        | Insolation |
| Insolation     | 0.9865                  | 1          |
| UV index       | 0.8452                  | 0.8463     |
| Humidity       | -0.3223                 | -0.3375    |
| Temperature    | 0.2783                  | 0.2871     |
| Cloud cover    | -0.1825                 | -0.1775    |
| Wind speed     | -0.0423                 | -0.0517    |

## 2.2 데이터 구성 및 전처리

태양광 발전량과 기상정보 간 상관관계를 분석한 결과 일사량, 자외선 지수, 습도, 기온, 전운량, 풍속 순으로 발전량에 영향을 미치는 것을 확인하였다. 본 연구에서는 일사량, 자외선 지수, 습도, 기온, 전운량의 5가지 변수와 시간 정보를 나타내기 위해 추가적으로 월(month), 시간(hour)을 태양광 발전량 예측에 관한 입력변수로 선정하였다.

위의 입력 변수로 선정한 데이터는 단위 및 분포가 모두 다르기 때문에 데이터의 범위를 일치시키거나 분포를 유사하게 만들 필요가 있다. 본 연구에서는 식 (2)와 같이 데이터의 값이 0~1의 분포를 갖도록 변형하는 min-max 정규화를 사용하여 입력 데이터를 정규화하였다.

$$z = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2)$$

본 연구에서 사용한 데이터의 구성은 다음과 같다. 먼저, 발전소마다 각각 3개의 인버터를 통해 10분 간격으로 태양광 발전량을 수신하며, 기상관측 장비를 통해 10분 간격으로 일사량 정보를 기록한다. 또한 Dark Sky API를 통해 발전소 지역마다 시간 단위의 기온, 습도, 전운량, 자외선 지수 등의 과거 기상정보와 기상예보 데이터를 이용하였다. Dark Sky API의 기상예보 데이터는 최대 168시간 이내의 시간 단위 기상예보를 제공한다. 기상정보 데이터가 시간 단위로 존재하기 때문에 발전소 데이터의 발전량 정보와 일사량 정보를 각각 시간 단위로 통합하였고, 본 연구에서 시간 단위의 태양광 발전량을 예측하는 것을 목표로 하였다.

## 2.3 예측 모델 구성

### 2.3.1 LSTM(Long Short-Term Memory)

본 연구에서는 태양광 발전량 예측을 위해 시계열 데이터의 학습에 효과적인 LSTM(Long Short-Term Memory)<sup>[13,14]</sup>를 사용하였다. LSTM은 과거 학습결과를 현재 학습에 사용하는 딥러닝 네트워크인 RNN(Recurrent Neural Network)의 일종으로, cell state를 통해 학습이 반복됨에 따라 과거 학습 정보가 사라지는 장기 의존성(Long-Term Dependency) 문제를 해결하였다. LSTM은 neural network 모듈을 반복시키는 체인과 같은 형태를 하고 있으며, LSTM의 반복 모듈은 그림 1과 같다.

Cell state는 반복 모듈에 속하는 여러 개의 gate를 통해 업데이트되며 각 gate의 역할은 다음과 같다. 먼저, forget gate  $f_t$ 는 sigmoid 함수를 통해 어떤 정보를 버릴지 결정한다. Input gate  $i_t$ 는 sigmoid 및 tanh 함수를 통해 cell state에 어떤 정보를 저장할지 결정




그림 1. LSTM 반복 모듈  
Fig. 1. LSTM iterative module

한다. Output gate  $o_t$ 는 업데이트된 cell state를 바탕으로 어떤 정보를 내보낼지 결정하는 역할을 한다. 최종적으로  $C_t$ 는 과거의 cell state  $C_{t-1}$ 과 학습된 정보  $\tilde{C}_t$ 를 통해 업데이트되는 cell state를 의미한다. 각 gate와 cell state가 업데이트되는 과정은 식 (3)과 같다.

$$\begin{aligned}
 f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\
 i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\
 \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \\
 C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t \\
 o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\
 h_t &= o_t * \tanh(C_t)
 \end{aligned}
 \tag{3}$$

### 2.3.2 일사량 및 발전량 예측 모델 구조

본 연구에서는 태양광 발전량 예측을 위해 기상예보 데이터를 이용하였다. 하지만 기상예보 데이터에 태양광 발전량과 가장 밀접한 관계에 있는 일사량이 존재하지 않기 때문에, 먼저 기상정보를 통해 일사량을 예측하는 모델을 구성하였고 예측한 일사량과 기상정보를 통해 최종적으로 발전량을 예측하는 모델을 분리하였다. 일사량 예측 모델과 발전량 예측 모델 모두 LSTM을 이용하였으며 구조는 그림 2와 같다.

LSTM 기반 예측 모델 구조는 그림 1의 LSTM 반복 모듈이 체인 형태로 연결되어 있으며 그림 2의  $x$ 는 예측 모델의 입력 변수,  $h$ 는 예측 모델의 출력 데이터를 의미한다. 출력 데이터를 적절히 필터링하여 최종 일사량 및 발전량 값을 예측한다. 해당 모델은 시간 단위의 일사량 및 발전량을 구간 제한 없이 자유롭게 학습 및 예측이 가능하다는 장점이 있다.

Dark Sky API에서 제공받는 기상예보 데이터는 72시간 이상의 예보에 대해서는 정확도가 떨어지는 양상을 보였기 때문에, 실험에서는 72시간 동안의 일사량 및 발전량 예측을 진행하였다. 실험 결과, 일사량 예측 모델을 추가적으로 사용하는 것이 발전량 예




그림 2. LSTM 기반 예측 모델 구조  
Fig. 2. LSTM based forecast model structure

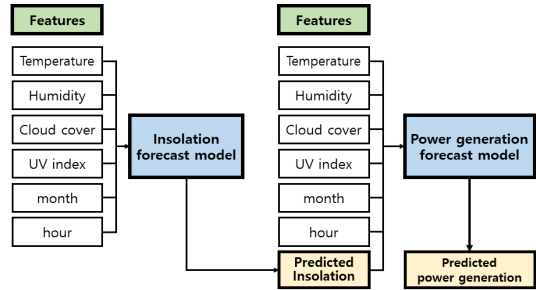


그림 3. 태양광 발전량 예측 프로세스  
Fig. 3. Solar photovoltaic power forecasting process

측 모델만 사용하는 것보다 더 높은 예측 정확도를 보였다. 일사량 예측 모델과 발전량 예측 모델을 이용하여 최종적으로 태양광 발전량을 예측하는 프로세스는 그림 3과 같다.

태양광 발전량 예측 프로세스는 먼저 일사량 예측 모델을 통해 기온, 습도, 전운량, 자외선 지수, 월(month), 시간(hour) 정보로 일사량을 예측한 다음, 동일한 정보에 예측한 일사량을 추가하여 발전량 예측 모델을 통해 최종적으로 태양광 발전량을 예측하는 과정으로 이루어진다.

## III. 실험

본 연구에서 제안한 딥러닝 기반의 예측 모델을 학습하기 위해 Python 3.6 기반의 TensorFlow 및 Keras 라이브러리를 사용하였다. 실험에 사용한 발전소 데이터는 시간 단위의 일사량 및 발전량을 포함하며, 기상 정보 데이터는 시간 단위의 기온, 습도, 전운량, 자외선 지수를 포함한다. 실험을 위해 제공받은 발전소 데이터는 2019년 2월 9일부터 2019년 9월 30일까지 존재하며, 예측 모델의 학습을 위해 동일한 기간의 기상 정보 데이터를 이용하였다. 학습 데이터의 기간이 1년 미만으로 짧기 때문에 본 연구의 실험에서 샘플링 편향 문제가 발생할 수 있는 한계점이 존재한다.

딥러닝 기반의 예측 모델을 학습할 때 학습 데이터의 편향 문제를 해결하기 위해 학습 데이터를 실제 예측 모델의 학습에 사용되는 train set, 학습 과정에서 예측 모델 성능 평가에 사용되는 validation set으로 나누는 과정이 필요하다. 실험에 사용한 발전량 데이터는 각 발전소마다 3개의 인버터를 통해 수신한 데이터로 구성되어 있다. 따라서 학습 데이터 중 2개의 인버터를 통해 수신한 발전량 데이터를 train set, 나머지 1개의 인버터를 통해 수신한 발전량 데이터를 validation set으로 구성하였다. 각 예측 모델의 정확

도를 평가하기 위해 식 (4)의 MAE(Mean Absolute Error) 및 NMAE(Normalized MAE)를 사용하였다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i|$$

$$NMAE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - x_i|}{capacity}$$
(4)

식 (4)에서  $n$ 은 데이터의 총 개수,  $y$ 는 실제 데이터 값,  $x$ 는 예측한 데이터 값,  $capacity$ 는 인버터의 발전 용량을 의미한다. NMAE는 MAE에 발전 용량을 나눈 값으로, 단위 발전 용량에 대한 오차율을 나타냄으로써 MAE보다 객관적인 평가가 가능하다. 본 연구에서 사용한 발전소 데이터의 인버터 발전 용량은 34kW이다. 또한 각 예측 모델의 학습을 위해 임의의 시점을 선택하여 이후 72시간 동안의 발전소 및 기상정보 데이터를 통해 학습 데이터를 구성하였다.

발전량 및 일사량 예측 모델의 하이퍼파라미터 설

정은 반복 실험을 통해 LSTM 반복 모듈 개수 10개, 손실 함수는 오차율 산정 방식과 같은 MAE, 최적화 기법은 ADAM(Adaptive Moment Estimation), 학습 epoch 횟수는 500회로 지정하였다. 학습 결과는 각각 그림 4, 그림 5와 같다.

학습 결과 그래프에서 train\_loss는 train set 학습 시의 loss, test\_loss는 validation set 학습 시의 loss를 의미한다. 각 예측 모델은 학습 epoch 150회까지 train\_loss와 test\_loss가 모두 낮아져 학습이 잘 이루어진 것을 확인할 수 있으며, 150회 이후부터는 test\_loss가 낮아지지 않아 학습이 제대로 이루어지지 않는 것을 확인하였다. 특히 발전량 예측 모델의 경우 test\_loss가 상승하여 overfitting이 일어나는 모습을 보였다. 예측 정확도 향상을 위해 각 예측 모델의 test\_loss가 가장 낮은 지점의 모델 가중치를 통해 예측 정확도 평가를 진행하였다.

LSTM 기반의 예측 모델 효율성 평가를 위해 일반적인 인공신경망 형태의 neural network를 깊게 쌓은 DNN(Deep Neural Network)과 오차율을 비교하였다.




그림 4. LSTM 기반 발전량 예측 모델 학습 결과  
Fig. 4. LSTM based Power generation forecast model training result




그림 6. DNN 기반 발전량 예측 모델 학습 결과  
Fig. 6. DNN based Power generation forecast model training result




그림 5. LSTM 기반 일사량 예측 모델 학습 결과  
Fig. 5. LSTM based Insolation forecast model training result




그림 7. DNN 기반 일사량 예측 모델 학습 결과  
Fig. 7. DNN based Insolation forecast model training result

두 모델 모두 동일하게 일사량 예측 모델을 적용하였으며 DNN의 하이퍼파라미터 설정 또한 반복 실험을 통해 5개의 layer로 구성하였고, 손실 함수는 MAE, 최적화 기법은 ADAM, 활성화 함수는 ReLU를 적용하였다. DNN으로 구성된 발전량 및 일사량 예측 모델의 학습 결과는 각각 그림 6, 그림 7과 같다. DNN 기반 예측 모델 학습 결과는 LSTM과 유사하게 epoch 150회 정도부터는 test\_loss가 감소하지 않는 모습을 보였고, 가장 낮은 test\_loss가 LSTM에 비해 높았다. 이는 LSTM이 DNN보다 발전량 및 일사량 데이터의 특성을 잘 학습하였음을 의미한다. 표 2는 DNN과 LSTM 기반 예측 모델의 최종 오차율을 비교한 것이다.

다음은 일사량 예측 모델의 효율성 평가를 위해 일사량 예측 모델을 사용한 경우와 사용하지 않은 경우를 나누어 실험을 진행하였다. 일사량 예측 모델을 사용하지 않은 경우는 기상정보(기온, 습도, 전운량, 자외선 지수)만으로 발전량을 예측하였으며, 일사량 예측 모델을 사용한 경우는 기상정보와 예측한 일사량을 통해 최종적으로 발전량을 예측하였다. 표 3은 두 경우의 MAE와 NMAE를 비교한 것이며, 일사량 예측 모델을 사용한 경우가 사용하지 않은 경우보다 발전량 예측에 있어 더 낮은 오차율을 보였다.

그림 8은 최종적으로 학습한 LSTM 기반 태양광 발전량 예측 모델을 이용하여 특정 시점의 72시간 기상예보를 통한 예측 발전량과 해당 구간의 실제 발전량을 비교한 것이다. 그림 8의 real은 실제 발전량, pred는 예측 발전량을 의미하며 그래프는 시간 단위의 발전량 변화를 나타낸 것이다. 결과를 보면 비교적 기상예보 시작 시점에서 가까운 구간의 예측 정확도

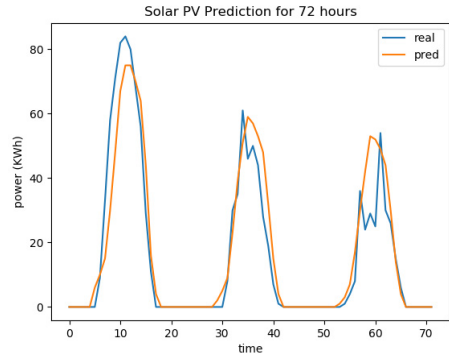


그림 8. 72시간 동안 실제 발전량 및 예측 발전량 비교  
Fig. 8. Comparison of real power generation and predicted power generation for 72 hours

가 높은 것을 확인할 수 있으며, 이는 기상예보 정확도가 가까운 시점일수록 높기 때문에 나타나는 현상이다.

#### IV. 결 론

본 연구에서는 LSTM 기반 일사량 예측 모델과 발전량 예측 모델을 통해 시간 단위의 태양광 발전량을 구간 제한 없이 예측하는 기법을 제안하였다. 태양광 발전량과 가장 밀접한 관계에 있는 일사량을 기상정보를 통해 먼저 예측하였고, 예측한 일사량과 기상정보를 통해 최종적으로 태양광 발전량을 예측하여 일사량을 예측하지 않은 경우에 비해 높은 예측 정확도를 보였다. 실험 결과 일반적인 딥러닝 기법인 DNN과 비교하여 시계열 특성을 잘 학습할 수 있는 LSTM 기반 예측 모델의 정확도가 우수하였고, 0.0454의 NMAE로 낮은 오차율을 기록하였다. 또한 같은 종류의 과거 기상정보와 기상예보 데이터를 제공해주는 Dark Sky API를 사용하여 과거 기상정보와 발전소 데이터를 통해 예측 모델을 학습한 다음, 신뢰성 있는 기상예보 데이터를 통해 미래의 태양광 발전량을 예측하였다. 결과적으로 제안하는 기법은 기존 연구들에 비해 시간 단위의 세밀한 발전량 예측이 가능하며, 정해진 시점이 아닌 원하는 구간의 발전량 예측을 하여 가용성이 높다. 해당 연구를 통해 정확도 높은 태양광 발전량 예측을 제공하여 태양광 발전 및 기존 화석 연료 발전의 전력 생산 계획을 효율적으로 세울 수 있다. 또한 최근 주목받고 있는 태양광 발전 사업에 있어 예상 발전량을 통해 합리적인 전력 거래 가격을 결정할 수 있으며, 이에 따라 전력 계통의 안정성을 확보하여 경제성을 향상시킬 수 있을 것으로 기대된다.

표 2. DNN과 LSTM 기반 예측 모델의 오차율 비교  
Table 2. Comparison of error rate with DNN and LSTM based forecast model

| Error | LSTM   | DNN    |
|-------|--------|--------|
| MAE   | 1.5424 | 1.9347 |
| NMAE  | 0.0454 | 0.0569 |

표 3. 예측 일사량을 사용한 경우와 사용하지 않은 경우의 오차율 비교  
Table 3. Comparison of error rate with and without forecasted insolation

| Error | With forecasted insolation | Without forecasted insolation |
|-------|----------------------------|-------------------------------|
| MAE   | 1.5424                     | 1.9347                        |
| NMAE  | 0.0454                     | 0.0569                        |

향후 연구 방향으로는 먼저 본 연구의 실험 데이터가 1년 미만으로 짧기 때문에 발생 가능한 샘플링 편향 문제를 해결하기 위해 보다 장기간의 실험 데이터를 획득하여 실험을 다시 진행할 계획이다. 또한 본 연구에서 사용한 기상정보 데이터뿐만 아니라 기상위성의 고해상도 일사량 사진을 통해 이미지 학습에 강한 CNN과 RNN 계열의 융합 딥러닝 모델을 구성하여 예측 정확도를 향상시킬 계획이다.

### References

[1] "About Renewable Energy," Green Energy Institute, Retrieved Oct. 10, 2019, from <http://gei.re.kr/>

[2] N. Sharma, P. Sharma, D. Irwin, and P. Shenoy, "Predicting solar generation from weather forecasts using machine learning," in *Proc. IEEE Int. Conf. Smart Grid Commun.*, pp. 528-533, Oct. 2011.

[3] S. M. Lee and W. J. Lee, "Development of a system for predicting photovoltaic power generation and detecting defects using machine learning," *J. KIPS Comput. and Commun. Syst.*, vol. 5, no. 10, pp. 353-360, Oct. 2016.

[4] J. Wang, R. Ran, and Y. Zhou, "A short-term photovoltaic power prediction model based on an FOS-ELM algorithm," *Appl. Sci.*, vol. 7, no. 4, Apr. 2017.

[5] K.Y. Bae, H. S. Jang, and D. K. Sung, "Solar power prediction based on machine learning scheme and its error analysis," in *Proc. Symp. KICS*, pp. 13-14, Jan. 2017.

[6] Hugo T. C. Pedro and Carlos F. M. Coimbra, "Assessment of forecasting techniques for solar power production with no exogenous inputs," *Solar Energy*, vol. 86, no. 7, pp. 2017-2028, Jul. 2012.

[7] C. Chen, S. Duan, T. Cai, and B. Liu, "Online 24-h solar power forecasting based on weather type classification using artificial neural network," *Solar Energy*, vol. 85, no. 11, pp. 2856-2870, Nov. 2011.

[8] Y. Li, Y. Su, and L. Shu, "An ARMAX model for forecasting the power output of a grid connected photovoltaic system," *Renewable*

*Energy*, vol. 66, no. 1, pp. 78-89, Jun. 2014.

[9] Y. Li, Y. He, Y. Su, and L. Shu, "Forecasting the daily power output of a grid-connected photovoltaic system based on multivariate adaptive regression splines," *Applied Energy*, vol. 180, no. 15, pp. 392-401, Oct. 2016.

[10] A. Saberian, H. Hizam, M. A. M. Radzi, M. Z. A. Ab Kadir, and M. Mirzaei, "Modelling and prediction of photovoltaic power output using artificial neural networks," *Int. J. Photoenergy*, vol. 2014, Article ID 469701, Apr. 2014.

[11] C.-D. Dumitru, A. Gligor, and C. Enachescu, "Solar photovoltaic energy production forecast using neural networks," *Procedia Technol.*, vol. 22, pp. 808-815, 2016.

[12] Dark Sky API, Retrieved Oct. 10, 2019, from <http://darksky.net/dev>

[13] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, Nov. 1997.

[14] *Understanding LSTM Networks*, Retrieved Oct. 10, 2019, from <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

김 용 수 (Yongsu Kim)



2019년 2월 : 부산대학교 전기  
컴퓨터공학부 졸업  
2019년 3월~현재 : 부산대학교  
전기전자컴퓨터공학과 석사  
과정  
<관심분야> 지능형IoT, 딥러닝,  
인공지능

[ORCID:0000-0001-6169-5537]

이 상 현 (Sanghyun Lee)



2019년 2월 : 부산대학교 전기  
컴퓨터공학부 졸업  
2019년 3월~현재 : 부산대학교  
전기전자컴퓨터공학과 석사  
과정  
<관심분야> 블록체인, 정보보  
호, 인공지능

[ORCID:0000-0002-1188-6551]

김 호 원 (Howon Kim)



1993년 2월 : 경북대학교 공학사  
1995년 2월 : 포항공과대학교 공  
학석사  
1999년 2월 : 포항공과대학교 공  
학박사  
2004년 : Ruhr University Bochum,  
Post Doctorial

1998년~2008년 : 한국전자통신연구원 팀장  
2008년~현재 : 부산대학교 전기컴퓨터공학부 교수  
<관심분야> 정보보호, 지능형IoT, FPGA/ASIC, 인공  
지능

[ORCID:0000-0001-8475-7294]