

Prediction of Solar Photovoltaic Power Generation by Weather Using LSTM

Saem-Mi Lee*, Kyu-Cheol Cho*

*Student, Dept. of Computer Science, Inha Technical College, Incheon, Korea

*Professor, Dept. of Computer Science, Inha Technical College, Incheon, Korea

[Abstract]

Deep learning analyzes data to discover a series of rules and anticipates the future, helping us in various ways in our lives. For example, prediction of stock prices and agricultural prices. In this research, the results of solar photovoltaic power generation accompanied by weather are analyzed through deep learning in situations where the importance of solar energy use increases, and the amount of power generation is predicted. In this research, we propose a model using LSTM(Long Short Term Memory network) that stand out in time series data prediction. And we compare LSTM's performance with CNN(Convolutional Neural Network), which is used to analyze various dimensions of data, including images, and CNN-LSTM, which combines the two models. The performance of the three models was compared by calculating the MSE, RMSE, R-Squared with the actual value of the solar photovoltaic power generation performance and the predicted value. As a result, it was found that the performance of the LSTM model was the best. Therefore, this research proposes predicting solar photovoltaic power generation using LSTM.

▶ **Key words:** deep learning, prediction, weather, solar photovoltaic power generation, LSTM

[요 약]

딥러닝은 주가 및 농산물 가격 예측과 같이 데이터를 분석해 일련의 규칙을 발견하고 미래를 예상해 우리의 삶에서 다양한 도움을 주고 있다. 본 연구는 태양광 에너지 사용의 중요성이 늘어나는 상황에서 기상에 따른 태양광 발전 실적을 딥러닝을 통해 분석하고 발전량을 예측한다. 본 연구에서는 시계열 데이터 예측에서 두각을 나타내고 있는 LSTM(Long Short Term Memory network)을 사용한 모델을 제안하며 이미지를 비롯한 다양한 차원의 데이터를 분석할 때 사용되는 CNN(Convolutional Neural Network)과 두 모델을 결합한 CNN-LSTM과의 성능을 비교한다. 세 가지 모델의 성능은 태양광 발전 실적의 실제값과 딥러닝을 통해 예측한 값으로 MSE, RMSE, 결정계수를 계산하여 비교하였고 그 결과 LSTM 모델의 성능이 가장 우수한 것으로 나타났다. 따라서 본 연구는 LSTM을 사용한 태양광 발전량 예측을 제안한다.

▶ **주제어:** 딥러닝, 예측, 기상, 태양광 발전, LSTM

-
- First Author: Saem-Mi Lee, Corresponding Author: Kyu-Cheol Cho
 - *Saem-Mi Lee (saemmi.lee@gmail.com), Dept. of Computer Science, Inha Technical College
 - *Kyu-Cheol Cho (kccho@inhac.ac.kr), Dept. of Computer Science, Inha Technical College
 - Received: 2022. 07. 04, Revised: 2022. 08. 09, Accepted: 2022. 08. 09.

I. Introduction

현재 주요 에너지원은 석유, 석탄, 천연가스와 같은 화석연료이다. 화석연료는 수백만 년 전 동식물의 사체가 퇴적하면서 생긴 지하자원이다. 이러한 화석연료는 연소 과정에서 온실가스가 배출되고 이에 따라 지구온난화라는 커다란 환경문제를 초래했다. 지구온난화로 인해 세계 각국에서는 이상 기후 현상과 해수면 상승 등의 다양한 문제가 발견되고 있다. 무엇보다 화석연료는 소모해버리면 다시 자원으로 활용하기까지 많은 시간이 걸리기 때문에 미래에 고갈되지 않고 환경에 악영향을 미치지 않는 신재생 에너지의 사용이 절실하다. 또한 화석연료는 특정 지역에만 존재해 많은 나라에서는 수입해서 사용하고 있으나 신재생 에너지의 사용이 확대된다면 수입 의존도를 극복할 수 있을 것이다[1].

약 50억 년이 남은 태양의 수명으로 인해 태양을 이용한 신재생 에너지의 전망이 밝다. 종류는 태양열 발전과 태양광 발전이 있으며 우리나라에서는 태양광 발전이 더 선호된다. 그 이유는 태양광 발전은 햇빛을 받으면 광전 효과에 의해 전기를 발생시키는 태양 전지를 사용해 열에너지로 변환할 필요 없이 간단하기 때문이다[2]. 실제로 산업통상자원부에서 제공하는 신재생 에너지 생산량을 살펴보면 2016년부터 2020년까지 태양열보다 태양광의 에너지 발전량이 더 많다.

태양광 패널은 외부에 설치되어 햇빛을 받아야 하므로 기본적으로 날씨에 많은 영향을 받으며 계절과 시간에 따라 발전량이 일정한 패턴을 보이고 변화하는 시계열의 특성을 가진다. 이러한 점을 고려하여 본 연구에서는 기상 데이터와 함께 태양광 에너지 발전량을 분석한다.

인공지능 구현 방법의 하나인 딥러닝은 현재 주가 및 농산물 가격 예측과 같이 데이터를 분석해 일련의 규칙을 발견하고 미래를 예상해 우리의 삶에서 다양한 도움을 주고 있다[3]. 본 연구에서는 이러한 딥러닝을 통해 기상에 따른 태양광 발전 실적을 분석하고 발전량을 예측한다.

본 연구는 태양광 발전량을 예측함으로써 목표하는 발전량을 달성하기 위해 발전기의 가동 시간과 기간, 추가 가동 및 정지와 같이 기상 예보에 따라 발전기 운용을 계획하는 데에 도움을 주어 전력 사용 안정화에 이바지하는 것을 목표로 한다.

본 연구의 구성은 다음과 같다. 2장에서는 본 연구와 관련된 연구에 대해 기술한다. 3장에서는 본 연구에서 제안하는 Long Short Term Memory network(이하, LSTM) 모델을 사용한 분석에 대해 기술한다. 4장에서는

LSTM과 함께 Convolutional Neural Network(이하, CNN) 모델, CNN과 LSTM을 결합한 모델의 결과를 비교하고 5장에서는 결론에 대해 기술한다.

II. Preliminaries

1. Related works

1.1 LSTM (Long Short Term Memory network)

LSTM은 RNN(Recurrent Neural Network)의 일종이다. RNN은 은닉층에서 나온 결괏값이 다시 은닉층으로 돌아가 새로운 입력값으로 연결되는 순환구조이다[4]. 이러한 RNN의 장기 의존성 문제를 해결한 인공 신경망이 LSTM이다. RNN은 단기 메모리만을 가지고 학습했다면, LSTM은 단기 메모리와 장기 메모리를 모두 사용하여 학습한다. 이는 RNN과 비교해 과거의 정보를 훨씬 더 잘 반영한다는 장점이 있다[5].

그림 1은 LSTM의 구조를 나타낸다. Cell state는 정보가 바뀌지 않고 그대로 흐르도록 한다. Forget gate는 Sigmoid 함수를 사용해 Cell state에서 어떤 정보를 버릴 것인지 정한다. Input gate는 Sigmoid 함수와 TanH 함수를 사용해 앞으로 들어오는 정보 중 어떤 것을 Cell state에 저장할 것인지 정한다. 이후 과거 Cell state를 업데이트하여 새로운 Cell state를 만든다[6].




Fig. 1. LSTM structure

LSTM은 시계열 데이터 분석에서 두각을 나타내고 있다. 발전량 및 기상 데이터를 활용해 태양광 발전량을 예측한 연구[7]에서는 MLR, MLP, LSTM에 적용하여 비교하였다. 그 결과, LSTM의 예측 오차가 낮은 모습을 확인하였다. 본 연구는 이를 참고하여 기상 데이터를 수집하고 LSTM을 활용하였다.

1.2 CNN (Convolutional Neural Network)

CNN은 그림 2와 같이 입력 계층과 합성곱 계층 (Convolution layer), 풀링 계층(Pooling layer)과 완전 연결 계층 그리고 출력 계층으로 구성되어 있다[8]. 입력 층을 통해 데이터를 입력하고 합성곱 계층에서는 입력된 데이터와 필터를 사용하여 합성곱 연산을 수행한다. 풀링 계층에서는 데이터의 크기를 축소한다. 이렇게 얻어진 출력 데이터는 크기는 작아지며, 강한 특성이 출력된다[9].




Fig. 2. CNN structure

CNN은 이미지 분석에서 두각을 나타내고 있지만 시계열 데이터에도 적용할 수 있다. 하천 홍수를 예측한 연구 [10]에서는 하루 단위로 측정된 하천 수위 및 강수량 데이터를 CNN에 적용하였다. 본 연구는 이를 참고하여 CNN을 활용해 시계열 데이터를 분석하였다.

1.3 CNN-LSTM

CNN과 LSTM이 결합된 모델인 CNN-LSTM은 최근 시계열 데이터에서 뛰어난 성능으로 주목받고 있는 알고리즘이다. CNN이 합성곱 연산을 통해 데이터의 특징을 추출하면 이어서 LSTM이 시간적 특성을 반영해 예측한다[11].

미세먼지 오염도를 예측한 연구[12]에서는 환경 데이터를 CNN-LSTM에 적용해 시계열 예측 성능을 개선하였다. 본 연구는 이를 참고하여 CNN-LSTM을 활용해 시계열 데이터를 분석하였다.

III. Prediction of Solar Photovoltaic Power Generation Using LSTM

본 연구는 신재생 에너지 사용의 중요성이 증가하는 상황에서 기상에 따른 태양광 발전량을 예측하기 위해 시계열 데이터 예측에서 두각을 나타내고 있는 LSTM을 사용한 모델을 제안한다.

1. Research architecture

본 연구는 태양광 발전량을 예측하기 위해 인천 수산 정수장의 태양광 발전 실적 데이터를 사용하였다. 또한 햇빛을 받아야 전기를 발생시키는 태양전지를 사용하기 때문에 기본적으로 날씨에 많은 영향을 받는 태양광 발전의 특성을 고려하여 기상청에서 제공하는 종관 기상 관측 자료를 함께 사용하였다.

먼저 태양광 발전 실적 데이터와 기상 데이터의 전처리를 진행한 후에 LSTM, CNN, CNN-LSTM 알고리즘을 사용한 모델을 생성하고 평가하여 기상에 따른 태양광 발전량을 예측한다.

2. Process

2.1 Data preprocessing

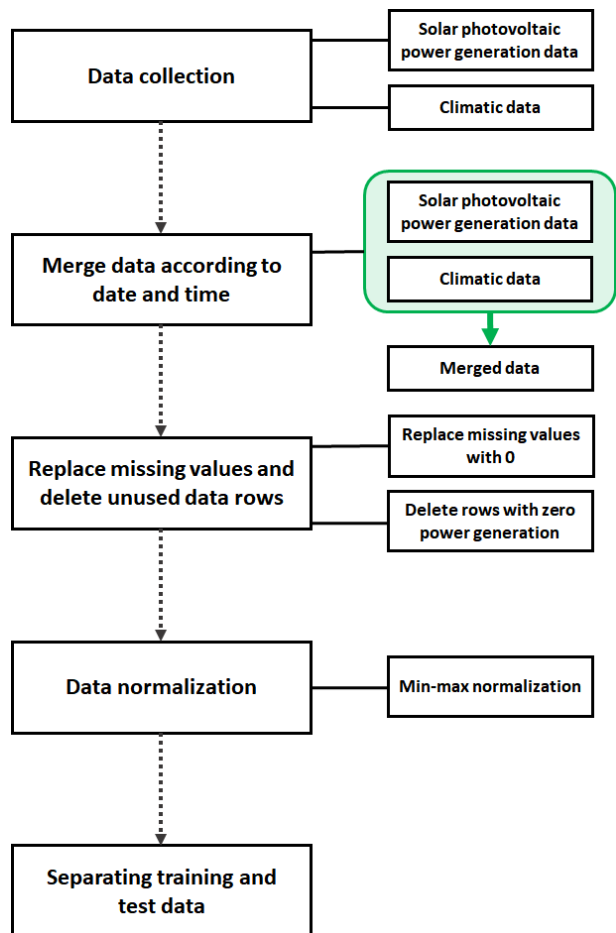


Fig. 3. Data preprocessing

그림 3은 본 연구의 데이터 전처리 과정을 도식한 것이다.

본 연구를 위해 태양광 발전량 및 기상 데이터 수집을 진행했다. 태양광 발전량 데이터는 공공 데이터 포털에서

한국 남부 발전의 인천 수산정수장 태양광 발전 실적을 수집했다. 기상 데이터는 기상청 기상 자료 개방 포털에서 종관 기상 관측 자료를 수집했다. 종관 기상 관측 자료는 기온(°C), 강수량(mm), 습도(%), 일사(MJ/m2), 운량(10분위)이 포함된 데이터이다.

그림 4는 태양광 발전 실적 데이터 중 일부만 나타낸 것이다. 시간에 흐름에 따라 발전량의 증가, 감소가 일정한 패턴으로 나타나는 걸 확인할 수 있었다.

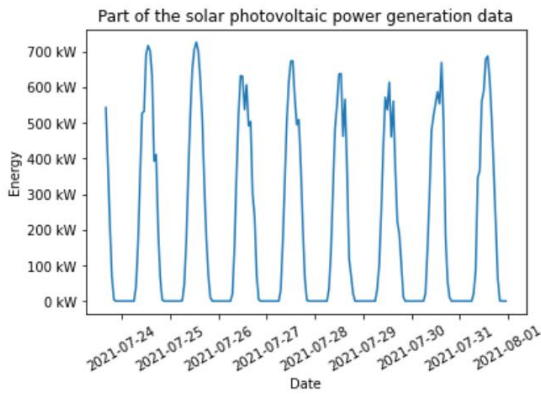


Fig. 4. Part of the solar photovoltaic power generation data graph

태양광 발전량 데이터와 기상 데이터 모두 2019년 8월 1일부터 2021년 7월 31일까지 1시간 단위로 총 2년의 데이터를 추출했다. 이후 따로 수집한 발전량 데이터와 기상 데이터를 날짜와 시간에 맞추어 하나의 데이터 셋으로 가공했다.

병합한 데이터에서 첫 번째로 강수량 및 일사량 데이터의 누락 값을 일괄적으로 0으로 대체했다. 누락값을 다른 값으로 대체하는 이유는 데이터에 NAN 값이 포함된 경우, 손실 값이 비정상적으로 높거나 NAN 값으로 나오기 때문이다. 종관 기상 관측 자료 중 강수량과 일사량 데이터는 관측된 값이 0으로 연속되면 데이터가 누락된다. 이러한 이유로 인해 해당 데이터의 누락 값을 0으로 대체했다[13]. 두 번째로 태양광 발전량이 0인 행을 삭제했다. 발전량이 0인 경우는 발전을 작동시키지 않은 경우이므로 모델의 학습에 혼란을 줄 수 있어 제거했다.

단위와 크기가 다른 데이터들이 큰 값에 편향되지 않기 위해 정규화를 진행했다[14]. 모든 데이터는 최소-최대 정규화(Min-Max Normalization)를 적용하여 0과 1 사이의 값으로 변환하였다.

전처리가 완료된 데이터는 훈련 데이터와 테스트 데이터로 나누어 주었다.

2.2 Activation function

활성화 함수는 이전 층의 결과값을 다음 층의 뉴런으로 전달하며 모델의 복잡도를 올리는 비선형 변환(Non-linear Transformation)을 담당한다[15].




Fig. 5. LeRU, TanH graph

본 연구에서는 LSTM을 활용한 회귀 분석을 위해 활성화 함수로는 TanH(Hyperbolic Tangent)를 사용하였다. 이유는 다음과 같다. LSTM은 과거의 값들이 반복적으로 사용된다. 이러한 특성을 고려하여 그림 5를 살펴보면 ReLU(Rectified Linear Unit)는 1 이상의 값이 나오면 발산할 확률이 높다. 그러므로 출력층의 값을 -1과 1 사이의 값으로 정규화하는 TanH를 사용했다[16].

2.3 Loss function

본 연구에서는 LSTM을 활용한 회귀 분석을 위해 손실 함수로는 MSE(Mean Squared Error)를 사용하였다. 손실 함수는 신경망의 성능을 나타내는 지표이다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \dots (1)$$

식(1)은 MSE의 공식이다. 여기서 n은 사례를 의미한다. y_i 는 i번째 사례의 실제값, \hat{y}_i 는 i번째 사례의 예측값이다. MSE는 제곱 연산으로 오차가 양수이든 음수이든 누적값을 증가시킨다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \dots (2)$$

추가로 식(2)은 RMSE의 공식이며 MSE에 제곱근을 적용한 값이다[17].

3. Summary of a LSTM model

그림 6은 LSTM을 사용한 모델의 구조이다. LSTM과 Dense 층을 차례로 쌓아 구성하였다.

```
Model: "sequential"
-----
Layer (type)                Output Shape          Param #
-----
lstm (LSTM)                  (None, 32)           4864
dense (Dense)                (None, 1)            33
-----
Total params: 4,897
Trainable params: 4,897
Non-trainable params: 0
```

Fig. 6. Summary of a LSTM model

IV. Experiment

실험을 통해 LSTM 모델과 CNN 모델, CNN-LSTM 모델의 결과를 비교한다. 세 가지 모델은 모두 3장에서 전처리를 마친 데이터로 학습하였다.

1. Model to compare

1.1 CNN

```
Model: "sequential"
-----
Layer (type)                Output Shape          Param #
-----
conv1d (Conv1D)              (None, 19, 64)       704
max_pooling1d (MaxPooling1D) (None, 9, 64)         0
flatten (Flatten)            (None, 576)           0
dense (Dense)                (None, 50)           28850
dense_1 (Dense)              (None, 1)             51
-----
Total params: 29,605
Trainable params: 29,605
Non-trainable params: 0
```

Fig. 7. Summary of a CNN model

그림 7은 CNN을 사용한 모델의 구조이다. CNN과 Max pooling 층 그리고 Flatten과 2개의 Dense 층을 쌓아 구성하였다. 또한 활성화 함수로 ReLU를 사용하였다.

1.2 CNN-LSTM

그림 8은 CNN-LSTM을 사용한 모델의 구조이다. CNN과 Max pooling 층 그리고 Flatten 층을 쌓은 뒤 LSTM과 Dense 층을 쌓아 구성하였다. 또한 활성화 함

수로 CNN 층은 ReLU, LSTM 층은 TanH를 사용하였다.

```
Model: "sequential"
-----
Layer (type)                Output Shape          Param #
-----
time_distributed (TimeDistri (None, None, 10, 64) 384
buted)
time_distributed_1 (TimeDis (None, None, 5, 64)  0
tributed)
time_distributed_2 (TimeDis (None, None, 320)    0
tributed)
lstm (LSTM)                  (None, 50)           74200
dense (Dense)                (None, 1)            51
-----
Total params: 74,635
Trainable params: 74,635
Non-trainable params: 0
```

Fig. 8. Summary of a CNN-LSTM model

2. Comparing validation loss

그림 9는 LSTM, CNN, CNN-LSTM 모델의 검증 손실 값을 나타내는 그래프이다.

손실 값은 딥러닝 모델의 출력값과 실제 데이터와의 오차를 의미한다. 그렇기에 손실 값이 0에 가까울수록 훈련이 잘된 모델이다[18].

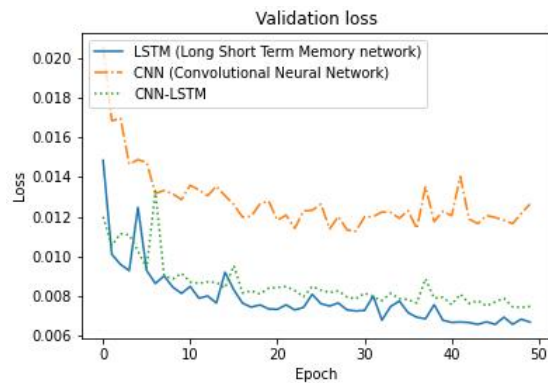


Fig. 9. Validation loss graph

세 가지 모델 모두 50번의 훈련 동안 손실 값이 감소하는 추세를 확인할 수 있다. 표 1은 마지막 검증 손실 값을 수치로 나타낸 것이다. 세 가지 모델 중 LSTM의 검증 손실 값이 가장 낮은 것을 확인했다.

Table 1. Validation loss

	LSTM	CNN	CNN-LSTM
val_loss	0.0067	0.0126	0.0075

3. Comparing train loss

그림 10은 LSTM, CNN, CNN-LSTM 모델의 훈련 손실 값을 나타내는 그래프이다.

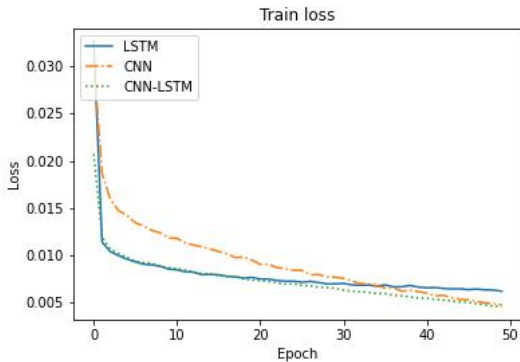


Fig. 10. Train loss graph

세 가지 모델 모두 50번의 훈련 동안 감소하는 추세를 확인할 수 있다. 표 2는 마지막 훈련 손실 값을 수치로 나타낸 것이다.

Table 2. Train loss

	LSTM	CNN	CNN-LSTM
loss	0.0062	0.0047	0.0046

4. Comparison of LSTM, CNN and CNN-LSTM

그림 11은 태양광 발전량의 실제값과 딥러닝을 통해 예측한 값을 나타내는 그래프이다. 실제 태양광 발전량과 비교하여 세 가지 모델 모두 비슷한 추세로 예측하였다. 이후 그래프의 뒷부분을 확대하여 확인한 결과, LSTM이 예측한 값이 실제값과 가장 유사하였다.

더욱 정확한 차이를 수치로 확인하기 위해 태양광 발전량의 실제값과 딥러닝을 통해 예측한 값으로 MSE(Mean Squared Error)와 RMSE(Root Mean Squared Error)를 계산하였다. MSE의 공식은 3장의 식(1)과 같으며 RMSE의 공식은 3장의 식(2)와 같다.

표 3은 세 가지 모델의 MSE와 RMSE를 나타낸다. 그 결과, LSTM의 MSE와 RMSE 값이 가장 작게 나오는 것을 확인했다. 즉, LSTM이 세 가지 모델 중 가장 실제와 유사하게 예측된다는 것을 의미한다.

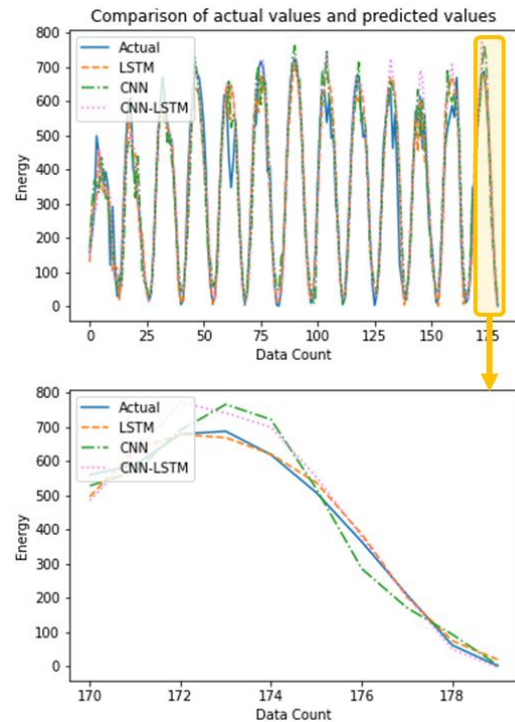


Fig. 11. Comparison of actual values and predicted values graph

Table 3. MSE, RMSE

	MSE	RMSE
LSTM	4592.16	67.76
CNN	4994.89	70.67
CNN-LSTM	5291.57	72.74

추가로 모델의 적합도를 평가하기 위해 결정계수(R-Squared)를 이용하였다. 결정계수는 회귀모델에서 독립변수가 종속변수를 얼마나 설명하는지를 가리키는 지표이다. 0과 1 사이의 값을 가지며 1에 가까울수록 설명력이 높다고 할 수 있다[19].

표 4는 세 가지 모델의 결정계수를 나타낸다. 그 결과, LSTM의 결정계수가 가장 1에 가까웠다.

따라서 태양광 발전량 예측에는 LSTM 모델을 사용하는 것을 제안한다.

Table 4. R-Squared

	R-Squared
LSTM	0.9173
CNN	0.9029
CNN-LSTM	0.8971

V. Conclusions

본 연구는 화석연료의 사용으로 야기된 지구온난화라는 환경문제로 신재생 에너지 사용의 중요성이 증가하는 상황에서 기상에 따른 태양광 발전량을 예측하기 위해 연구를 진행하였다.

LSTM, CNN, CNN-LSTM 모델을 활용하여 실험을 진행하였고 그 결과 LSTM 모델로 예측한 값이 실제 태양광 발전량과의 차이가 가장 적다는 사실을 확인했다.

본 연구는 기상에 따른 태양광 발전량 예측을 위해 LSTM 모델 사용을 제안한다. 기상 예보에 따라 발전기의 가동 시간 및 기간 등 발전기 운용을 계획하고 발전량을 예측함으로써 전력 사용 안정화에 이바지할 것으로 기대된다. 또한 태양광뿐만 아니라 다른 신재생 에너지 발전량을 예측하는 데 활용할 수 있을 것으로 기대된다.

본 연구에서는 태양광 발전 실적과 종관 기상 관측 자료를 활용해 기상에 따른 태양광 발전량을 분석했지만, 발전기의 사양을 추가해 분석한다면 실제와 예측의 차이가 더 줄어들 것으로 기대된다. 또한 최근 대기 중의 먼지 농도가 높아지는 상황에서 태양광 패널에 햇빛이 도달해야 하는 태양광 발전의 특징을 고려해 보면 먼지 농도가 발전에 영향을 줄 수 있다. 그러므로 대기 중의 먼지 농도를 추가해 분석한다면 좋을 것으로 생각한다.

REFERENCES

- [1] Takeshi Wada, Kenro Dowara, Shunichi Hiraoka, and Yoosuke Yokata, "Get Together To Talk About Climate Change : Governance Roadmap for Ecological Conservation and Energy Conservation", Book Sense, pp. 88-89, 2016.
- [2] Jin-Pyo Hwang, and Chang-Hyun Lee, "Organic-inorganic Nanocomposite Adhesive with Improved Barrier Property to Water Vapor for Backsheets of Photovoltaic Modules", MEMBRANE JOURNAL, Vol. 25, No. 6, pp. 530-537, December 2015. DOI: 10.14579/MEMBRANE_JOURNAL.2015.25.6.530
- [3] Taek-Kyu Kim, Jae-Kwan Park, Seung-Hwan Seong, and Seo-Ryong Koo, "Implementation of interface module for prior study on deep learning model based on CNS", The Institute Of Electronics And Information Engineers, (), pp. 1258-1260, June 2021.
- [4] Hyun-Su Kim, "Control Performance Evaluation of Smart Mid-story Isolation System with RNN Model", Journal of the Korea Academia-Industrial cooperation Society, Vol. 21, No. 1, pp. 774-779, January 2020. DOI: 10.5762/KAIS.2020.21.1.774
- [5] Su-Jeong Lee, and Jae-Heon Lee, "Monitoring procedure of autocorrelated processes using the deep learning-based LSTM model", Journal of the Korean Data And Information Science Society, Vol. 33, No. 2, pp. 237-248, March 2022. DOI: 10.7465/jkdi.2022.33.2.237
- [6] Jong-Seok Choi, and Yong-Tae Shin, "LSTM-based Power Load Prediction System Design for Store Energy Saving", Journal of Korea Institute of Information, Electronics, and Communication Technology, Vol. 14, No. 4, pp. 307-313, August 2021. DOI: 10.17661/jkiiect.2021.14.4.307
- [7] Baek-Cheon Kim, Seung-Hwan Jung, Min-Seok Kim, Jong-Geun Kim, Han-Soo Lee, and Sung-Shin Kim, "Solar Power Generation Forecasting based on LSTM considering Weather Conditions", Journal of Korean Institute of Intelligent Systems, Vol. 30, No. 1, pp. 7-12, February 2020. DOI: 10.5391/JKIIS.2020.30.1.7
- [8] Sun-Gwan Han, Soo-Bin Hong, Young-Jun Kim, Byung-Chul Kim, Gi-Min Jeong, and Sung-Min An, "Artificial Intelligence Lab For AI Thinking", Sung An Dang, pp. 113-114, 2020.
- [9] Mo-Se Lee, and Hyun-Chul Ahn, "A Time Series Graph based Convolutional Neural Network Model for Effective Input Variable Pattern Learning : Application to the Prediction of Stock Market", Journal of Intelligence and Information Systems, Vol. 24, No. 1, pp. 167-181, March 2018. DOI: 10.13088/jjis.2018.24.1.167
- [10] Min-Woo Cho, Su-Jin Kim, and Hoe-Kyung Jung, "Implementation of CNN-based water level prediction model for river flood prediction", Journal of the Korea Institute of Information and Communication Engineering, Vol. 25, No. 11, pp. 1471-1476, November 2021. DOI: 10.6109/jkiice.2021.25.11.1471
- [11] Ye-In Kim, Se-Eun Lee, and Young-Sung Kwon, "Proposal of a Step-by-Step Optimized Campus Power Forecast Model using CNN-LSTM Deep Learning", Journal of the Korea Academia-Industrial cooperation Society, Vol. 21, No. 10, pp. 8-15, October 2020. DOI: 10.5762/KAIS.2020.21.10.8
- [12] Chul-Hyun Hwang, and Kwang-Wook Shin, "CNN-LSTM Combination Method for Improving Particular Matter Contamination (PM_{2.5}) Prediction Accuracy", Journal of the Korea Institute of Information and Communication Engineering, Vol. 24, No. 1, pp. 57-64, January 2020. DOI: 10.6109/jkiice.2020.24.1.57
- [13] Hye-Sook Son, Seok-Yeon Kim, and Yun Jang, "LSTM-based 24-Hour Solar Power Forecasting Model using Weather Forecast Data", KIISE Transactions on Computing Practices, Vol. 26, No. 10, pp. 435-441, October 2020. DOI: 10.5626/KTCP.2020.26.10.435
- [14] Yeon-Ju An, Taek-Kie Lee, and Kyu-Ho Kim, "Prediction of Photovoltaic Power Generation Based on LSTM Considering Daylight and Solar Radiation Data", The transactions of The

- Korean Institute of Electrical Engineers, Vol. 70, No. 8, pp. 1096-1101, August 2021. DOI: 10.5370/KIEE.2021.70.8.1096
- [15] Dong-Cheul Lee, and Byung-Joo Park, "Comparison of Deep Learning Activation Functions for Performance Improvement of a 2D Shooting Game Learning Agent", The Journal of The Institute of Internet, Broadcasting and Communication, Vol. 19, No. 2, pp. 135-141, April 2019. DOI: 10.7236/JIIBC.2019.19.2.135
- [16] Ho-Yong Eom, Dea-Hyeon Yu, and Seung-Muk Baek, "A Study on Performance Comparison of Long Short-term Memory Learning Techniques for Electric Load Forecasting", Korean Society for Precision Engineering, (), pp. 618-619, November 2021.
- [17] Ji-Yul Kim, and Seong-Jin Ko, "Comparison of DICOM images and various types of images", The Korea Institute of Convergence Signal Processing, Vol. 18, No. 2, pp. 76-83, December 2017.
- [18] Young-Dan Noh, and Kyu-Cheol Cho, "A Text Content Classification Using LSTM For Objective Category Classification", Journal of the Korea Society of Computer and Information, Vol. 26, No. 5, pp. 39-46, May 2021. DOI: 10.9708/jksci.2021.26.05.039
- [19] Young-Min Wi, Kyung-Bin Song, and Sung-Kwan Joo, "Load Forecasting for the Holidays Using a Data mining with the Coefficient of Determination", Journal of the Korean Institute of Electrical Engineers, (), pp. 552-553, July 2008.

Authors



Saem-Mi Lee received the A.S. degree in Computer Information Engineering from Inha Technical College, Korea, 2022 respectively. Ms. Lee entered the Inha Technical College in 2019 and graduated in 2022.

She has experience in IT practice and interested in IT and the fourth industrial revolution.



Kyu-Cheol Cho received the B.S., M.S. and Ph.D. degrees in Computer Science and Information Engineering from Inha University, Korea, in 2005, 2007 and 2013, respectively. Dr. Cho joined the faculty of the Department

of Computer Science at Inha Technical College, Incheon, Korea, in 2016. He is currently a assistant professor in the Department of Computer Science, Inha Technical College. He is interested in cloud computing, green IT and web programming.