

# 태양광 발전량 예측 시스템 최적화를 위한 데이터 영향성 연구

\*이주승, 강지명

한국전기연구원

jseunglee@keri.re.kr, jmkang@keri.re.kr

## A Study on the Data Correlation for Optimization of Photovoltaic Estimation System

Jooseung Lee, Jimyung Kang

Korea Electrotechnology Research Institute

### 요약

현재 탄소중립 등 지속적인 환경 보호 정책과 관련하여 태양광을 포함한 여러 재생에너지를 활용한 발전 시스템이 널리 보급되고 있다. 특히 지속적인 태양광 발전원의 보급률 증가에 따라 전력 에너지 품질 관리를 위해 태양광 발전의 변동성을 예측하기 위한 다양한 연구들이 진행 중이다. 본 논문에서는 딥러닝 모델을 기반으로 한 태양광 발전 시스템에서 예측을 위해 사용되는 여러 데이터가 예측 정확도에 미치는 영향성을 실험적으로 분석하여 제시한다. 본 연구의 결과를 통해 태양광 발전량 정보를 필요로 하는 여러 분야에서 경제성과 성능 정확도의 trade-off를 고려하여 최적화된 태양광 발전 시스템을 구축할 수 있을 것으로 기대한다.

### I. 서론

전 세계적으로 환경에 대한 관심이 증가하고 RE100, 탄소중립 등 환경 측면에서 지속 가능한 발전이 강조됨에 따라 기존의 탄소 배출량이 높은 발전 방식을 대체하기 위한 재생에너지 발전원들이 보급되고 있다. 특히 태양광 발전의 경우 설치 및 관리가 비교적 용이하여, 빠른 보급률 증가를 보이고 있다. 태양광 발전의 경우 계절 및 기후 변화 등에 따라 높은 변동성을 가지는데, 전력 품질 관리와 더불어 conservation voltage reduction (CVR)을 포함한 여러 에너지 응용 분야에서 정확도 높은 발전량 예측이 필요하며, 이를 위한 다양한 연구가 수행 중이다.

최신 태양광 발전량 에너지 예측 기술의 경우 시계열 데이터 특성을 갖는 발전량 데이터의 특성을 반영하여 recurrent neural network (RNN)의 한 종류인 long short-term memory (LSTM)[1] 기반으로 한 딥러닝 모델들이 예측 정확도 측면에서 높은 성능을 나타내고 있다[2-5]. 해당 연구들은 모델의 예측 성능 개선을 위해 clear-sky 및 센서를 통해 측정된 일사량과 온/습도, 풍량/풍속 등 직/간접적 환경 데이터의 종류를 다양화하거나 모델의 구조를 변경하는 방식을 적용하고 있다. 일반적으로 데이터 종류가 다양하거나 네트워크의 복잡도가 높을수록 좋은 성능을 얻을 수 있지만, 태양광 발전 설비 보급 측면에서 경제성을 필수적으로 고려해야 하므로, 각 요소들이 예측 정확도에 미치는 영향성을 검증해볼 필요가 있다.

본 논문에서는 태양광 발전원이 포함된 site의 CVR 운영 시스템 구축에 앞서, 태양광 발전량 예측 시스템 구현을 위해 합리적인 복잡도를 갖는 LSTM 모델을 기반으로 여러 센서 데이터들이 예측 정확도에 미치는 영향을 실험적으로 분석하고 그 결과를 제시한다.

### II. 데이터 영향성 분석 : 일사량 예측

태양광 발전의 원리에 따라 발전량 예측 정확도에 있어서 가장 중요한

표1. 실험 환경

항목	내용
데이터 관측 기간	2022년 4월 ~ 7월, 1분 단위 데이터 (shuffled)
예측 상세	과거 6시간 (360 points) 데이터를 통한 1분 후 일사량 예측
직접 데이터	센서 수평 일사량
간접 데이터	clear-sky 계산 일사량, 기온, 습도, 풍량
네트워크 구조	(2 layers * 16 cells LSTM) + fully connected layer
Metric	mean squared error (MSE)

표2. 일사량 예측 Feature Sets List

구분	Features
0	센서 일사량 (수평)
1	센서 일사량, clear-sky 일사량
2	센서 일사량, 습도
3	센서 일사량, 기온
4	센서 일사량, 풍량
5	전체

데이터는 일사량이다. 즉, 일사량을 보다 정확히 예측할 수 있다면 발전량 예측 정확도를 높일 수 있다. 해당 가능성 확인을 위해 먼저 센서를 통해 측정된 수평 일사량 데이터만을 사용하여 학습한 모델의 성능을 baseline으로 설정하고, 기타 간접적 환경 센서 데이터를 추가 학습 데이터로 사용하였을 때 일사량 예측 성능이 개선되는지 관찰하였다.

표3. 태양광 발전량 예측 Feature Sets List

구분	Features
0	발전량
1	발전량, clear-sky 일사량
2	발전량, 센서 수평 일사량
3	발전량, 습도
4	발전량, 기온
5	발전량, 풍량
6	발전량, 패널 온도
7	발전량, 패널 일사량
8	발전량, 패널 온도, 패널 일사량
9	발전량, 센서 수평 일사량, 습도, 기온, 풍량
10	전체

그림1. 일사량 예측 성능 비교 (MSE)

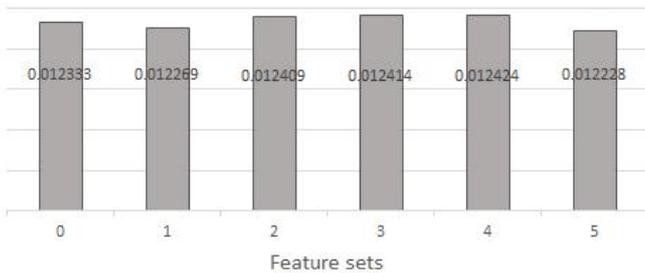
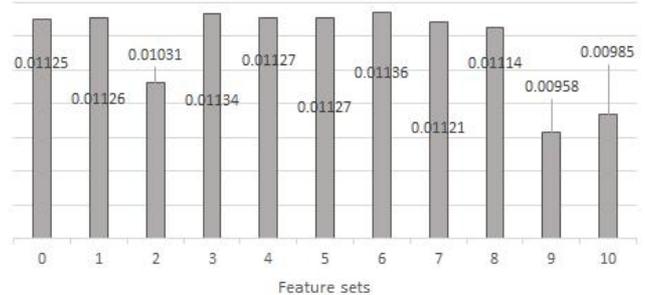


그림2. 태양광 발전량 예측 성능 비교 (MSE)



실험을 위해 사용한 상세 환경은 표1과 같다. 모델 학습 및 성능 비교 용이성을 위해 데이터는 정규화하여 사용하였으며, 학습 과정에서 계절 영향성을 배제하기 위해 10개의 shuffled set을 구성하여 실험하고 평균 성능을 관찰하였다. 더불어 개별 데이터 및 조합된 데이터의 영향성을 확인하기 위해 데이터들을 표2와 같이 feature sets으로 구성하여 실험을 진행하였다.

제시한 feature sets에 따른 일사량 예측 성능은 그림1과 같다. 센서 일사량 데이터만을 사용했을 때와 비교하여 간접 환경 데이터를 개별적으로나 종합적으로 사용하더라도 유의미한 성능 변화를 관찰할 수 없었으며, 학습 오차에 따라 수치적으로는 더 낮은 성능을 기록하기도 하였다. 결론적으로 일사량 예측 모델에서 간접 환경 데이터를 통한 성능의 개선을 기대하기는 어렵다는 점을 알 수 있으며, 오히려 일사량과 기타 간접 환경 데이터 간의 관련성이 낮다는 사실로부터 이후 수행할 발전량 예측 모델 실험에서 간접 환경 데이터 추가에 따른 성능 변화를 기대해 볼 수 있다.

### III. 데이터 영향성 분석 : 태양광 발전량 예측

일사량 예측 실험에서 사용한 데이터에 직/간접 데이터로 패널 일사량 및 패널 온도를 추가하여 최종 관심 값인 태양광 발전량 예측 모델에 대한 실험을 수행하였다. 기타 실험 환경은 표1에서 제시한 내용과 동일하게 설정하였으며, 상세 feature sets list는 표3과 같다.

태양광 발전량 예측 모델에 대한 실험 결과는 그림 2와 같다. 앞서 언급한 바와 같이 태양광 발전의 경우 일사량에 영향을 많이 받기 때문에, 개별 데이터 측면에서도 센서 수평 일사량을 추가 사용하였을 때 예측 성능이 개선되었음을 알 수 있다. 더불어 이전 실험과 달리 여러 데이터가 조합된 feature set 9, 10번을 사용하였을 때 유의미한 추가 성능 개선이 이루어졌음을 확인할 수 있다. 특이한 점으로는 패널의 일사량을 포함하여 패널의 데이터를 추가로 사용하였을 때 유의미한 성능 개선이 없다는 점인데, 이는 수평 일사량 센서 대비 패널에 설치한 일사량 센서의 성능 차이나 설치 방식의 차이로 생각해볼 수 있다. 본 실험의 결과를 통해 경제성과 성능을 모두 고려하여 9번 feature set 범위 내에서 합리적인 센서 구성이 가능함을 알 수 있다.

### IV. 결론 및 향후 계획

본 논문은 경제성 측면에서 합리적인 태양광 발전량 예측 시스템을 구축하기 위해 딥러닝 기반 예측 모델을 기반으로 직/간접적 데이터 사용에 따른 예측 성능 변화를 실험을 통해 제시하였다. 먼저 수평 일사만을 예측하는 경우 여러 간접 환경 데이터를 사용하더라도 일사량 데이터만을 사용한 경우와 비교하여 성능이 개선되지 않았으나, 발전량 예측 모델의 경우에는 수평 일사량을 포함한 주변 환경 데이터 조합을 사용하여 더 높은 예측 성능을 갖는 모델을 확보할 수 있었다. 추후에는 수평 일사량을 포함한 환경 센서 조합 범위 내에서 추가적인 세부 feature sets을 이용한 실험을 통해 최적의 센서 조합을 확정하고, 최종 목적인 CVR 운영 시스템에 사용할 태양광 예측 시스템을 구현할 계획이다.

### ACKNOWLEDGMENT

이 논문은 2022년도 정부(산업통상자원부)의 재원으로 한국에너지기술평가원의 지원을 받아 수행된 연구임(2022202090010A, 산업체 최적전압관리를 위한 예측제어 기술개발 및 실증)

### 참 고 문 헌

- [1] H. Sak *et al.*, "Long Short-Term Memory Recurrent Neural Network Architectures for Large Scale Acoustic Modeling", *Google INTERSPEECH*, 2014.
- [2] M. Konstantinou *et al.*, "Solar Photovoltaic Forecasting of Power Output Using LSTM Networks", *Atmosphere*, 2021.
- [3] Y. Wange *et al.*, "Short-term solar power forecasting = A combined long short-term memory and gaussian", *Sustainability*, 2021.
- [4] D. V. Pmbo *et al.*, "Increasing the Accuracy of Hourly Multi-Output Solar Power Forecast with Physics-Informed Machine Learning", *Sensors*, 2022.
- [5] T. Zhu *et al.*, "Solar Radiation Prediction Based on Convolution Neural Network and Long Short-Term Memory", *Energies*, 2021.