

공간 통계 기법의 병렬화 기반 특정 지점 기상 자료 추정을 활용한 태양광 발전량 예측 기법 연구

김민준, 유원석*, 조승우**, 이원철***

숭실대학교

minjoon99@soongsil.ac.kr, *wonseok4514@soongsil.ac.kr, **ico11290@soongsil.ac.kr, ***wlee@ssu.ac.kr

A Study on Photovoltaic Power Generation Forecasting Using Site-Specific Meteorological Data Estimation Based on Parallelized Spatial Statistical Methods

Min Joon Kim, Won Seok Yoo*, Seung Woo Jo**, Won Cheol Lee***

Soongsil Univ.

요약

본 논문에서는 태양광 발전소의 지리적 속성과 공간 통계 기법을 통해 추정된 기상 변수를 통합적으로 활용하는 딥러닝 기반 태양광(PV) 발전량 예측 프레임워크를 제안한다. 기존 예측 기법은 인근 기상 관측소 자료에 의존하여 발전소 위치별 공간적 기상 변동성과 지리적 특성을 충분히 반영하지 못하는 한계가 있다. 이를 해결하기 위해, 관측 지점이 없는 발전소 위치의 기상 변수를 공간 통계 기법을 통해 추정하고, 계산 효율 향상을 위해 해당 추정 과정을 월 단위로 분할하여 병렬 처리하였다. 추정된 기상 변수와 지리적 속성을 입력 특성으로 구성하여 딥러닝 모델에 적용한 결과, 제안한 프레임워크는 기존 방법 대비 예측 정확도 측면에서 일관된 성능 향상을 보였다.

I. 서 론

근래, 재생에너지 보급 확대 정책에 따라 한국전력거래소(KPX)는 태양광 발전량 예측 오차 기분을 강화하고 예측 제도를 전면 개편하고 있다. 이로 인해 평균 예측 오차율은 개선되었으나, 강화된 기준은 중소 태양광 발전사업자의 수익성 저하와 시장 경쟁력 약화로 이어질 수 있다는 지적도 제기되고 있다. 이러한 환경에서 태양광 발전량을 보다 정밀하게 예측 할 수 있는 기술적 접근의 중요성이 더 커지고 있다[1].

태양광 발전은 일사량, 일조시간, 기온, 운량 등 다양한 기상 요인에 직접적인 영향을 받으며, 구름 이동과 풍속 변화로 인한 시간적·공간적 변동성으로 인해 발전량 예측에 본질적인 불확실성이 존재한다. 출력 변동성을 완화하기 위한 에너지 저장장치(ESS)의 활용이 가능하나, 비용 증가로 인한 근본적인 해결책으로는 한계가 있다. 따라서 ESS 의존도를 낮추기 위해서는 발전량 예측 기술의 고도화가 필수적이다[2,3].

기존 태양광 발전량 예측 연구는 물리적 모델, 통계적 기법, 머신러닝 및 딥러닝 기반 접근으로 발전해 왔으며, 최근에는 기상 예보 정보와 인공지능을 결합한 데이터 기반 예측 기법이 활발히 연구되고 있다[4]. 그러나 대부분의 선행 연구들은 발전소 위치에서 직접 관측한 기상 자료의 부족으로 인해 AWS 또는 ASOS와 같은 인근 기상관측소 데이터를 대체함으로 활용함으로써, 발전소 위치별 공간적 기상 변동성을 충분히 반영하지 못하는 한계를 가진다[5,6].

이러한 문제를 보완하기 위해 공간 보간 기법을 활용하여 미관측 지점의 기상 변수를 추정하는 연구가 수행되어 왔다. 특히 크리깅(Kriging)이나 IDW 기반 보간 기법을 활용한 발전량 예측 연구에서 일정 수준의 정확도 향상이 보고되었으나, 단일 기간 분석이나 시계열적 상관성 미반영의 한계가 존재한다.[7]

본 논문에서는 이러한 한계를 극복하기 위해 태양광 발전소 인근 기상 관측 자료를 활용하여 병렬 처리 기반 크리깅 기법을 적용하고, 발전소 위치에서의 기상 변수를 효율적으로 추정한다. 추정된 기상 변수는 딥러닝 기반 예측 모델(DNN, RNN, LSTM, GRU)의 입력으로 활용되며, 공간

보간 기법 적용 여부에 따른 태양광 발전량 예측 성능을 비교·분석함으로써 제안 기법의 유효성을 검증한다.

II. 본론

1. 병렬 크리깅 기반 기상 변수 추정 프레임워크 구현

본 연구에서는 2013년부터 2015년까지의 기상청 관측소 400개 지점에서 수집된 시간별 기상 예보 자료와 전라도 A 지역에 위치한 태양광 발전소의 시간별 발전량 데이터를 활용하여 데이터베이스를 구축하였다. 구축된 데이터베이스는 태양광 발전 출력 예측 모델의 학습 및 검증을 위한 입력 데이터로 사용되었다. 발전소 위치에서 직접 관측이 어려운 기상 요소를 추정하기 위해 공간 통계 기반 크리깅 기법을 적용하였으며, 대규모 시계열 데이터 처리에 따른 계산 부담을 완화하기 위해 크리깅 연산을 월 단위로 분할하여 병렬 처리하였다. 병렬 연산은 Python 환경에서 병렬 처리를 지원하는 Joblib 라이브러리를 활용하여 구현되었으며, 시간 단위 크리깅 연산을 독립적인 작업 단위로 구성하였다. 최종적으로 병렬 처리 기반 크리깅을 통해 추정된 기상 요소들은 태양광 발전량 예측 모델의 입력 변수로 활용되었다. 그림 1은 본 연구에서 제안한 데이터 처리 및 병렬 크리깅 기반 기상 변수 추정 절차를 나타낸다.

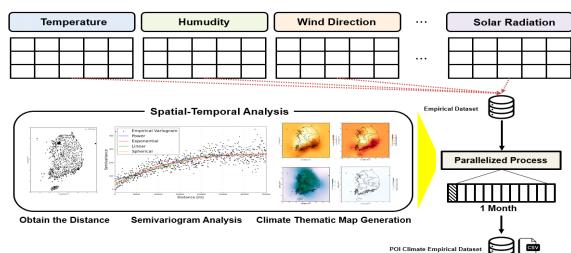


그림 1. 데이터 처리 및 병렬 크리깅 기반 기상 변수 추정 절차

2. 추정된 특정 지점 기상 데이터 기반 태양광 발전량 예측

DNN(Deep Neural Network)은 입력층과 출력층 사이에 다수의 은닉층(hidden Layer)들로 이루어진 인공신경망 구조로, 각 계층은 뉴런(neuron) 또는 노드(node)로 이루어져 있으며, 가중치와 활성화 함수(activation function)를 통해 상호 연결된다. 이러한 구조는 이미지 인식, 음성 인식, 자연어 처리 등 다양한 분야에서 활용되어 왔으며, 기존 단순 통계적 회귀 모델에 비해 비선형적 관계와 복잡한 데이터 패턴을 효과적으로 학습할 수 있어, 예측 정확도 측면에서 우수한 성능을 보인다[8].

RNN(Recurrent Neural Network)은 DNN 구조를 순환적으로 연결한 형태로, 이전 시점의 정보를 현재 학습에 반영할 수 있는 딥러닝 기반 시계열 모델이다. 일반적으로 tanh 또는 ReLU 활성화 함수를 사용하며, 시계열 길이가 증가할 경우 기울기 소실로 인해 장기 의존성(long-term dependency)를 효과적으로 학습하지 못하는 한계가 존재한다.

LSTM(Long Short-Term Memory)은 이러한 RNN의 한계를 개선하기 위해 제안된 구조로, 셀 상태(cell state)와 게이트 메커니즘을 통해 장기 정보를 안정적으로 유지할 수 있다. 이를 통해 장기 시계열 데이터에서도 효과적인 학습이 가능하다[9].

그림 2, 그림 3 및 그림 4는 크리깅 기법을 통해 추정된 기상 데이터를 입력으로 적용한 DNN, RNN 및 LSTM 기반 태양광 발전량 예측 결과를 나타내며, 인접한 기상 관측소의 실측 데이터를 입력으로 사용한 기존 예측 모델과의 성능을 비교·분석한 결과를 보여준다.

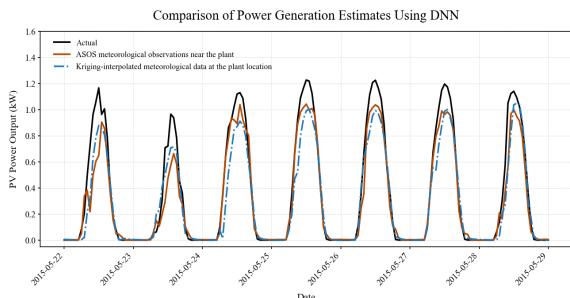


그림 3. DNN 기반 태양광 발전량 예측 결과 비교

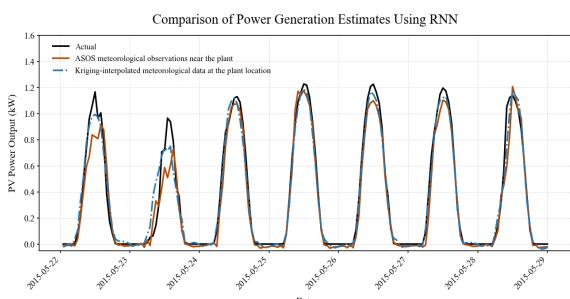


그림 4. RNN 기반 태양광 발전량 예측 결과 비교

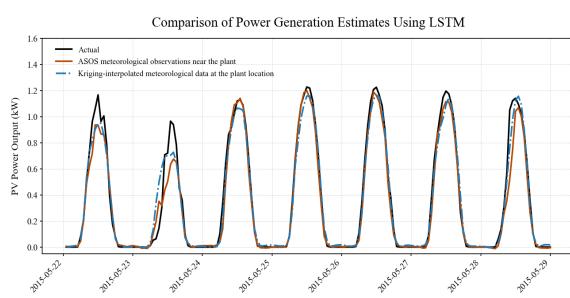


그림 5. LSTM 기반 태양광 발전량 예측 결과 비교

III. 결론

본 논문에서는 3년간의 기상 데이터를 효율적으로 처리하기 위해 병렬 크리깅 기법을 적용하였으나, 공간적 상관성만을 고려하고 시간적 상관성을 반영하지 못한 한계가 존재한다. 이로 인해 계절성 및 시간 의존성과 같은 시계열 특성이 충분히 반영되지 못하였다. 또한 단일 태양광 발전소를 대상으로 분석이 수행되어, 제안한 기법의 공간적 확장성과 다수 발전소의 환경에서의 일반화 성능에 대한 검증이 제한적이었다. 향후 연구에서는 복수 발전소를 대상으로 한 공간 확장성 평가와 함께, 시공간 크리깅 기법 또는 복합 예측 모델과의 결합을 통해 시간적·공간적 상관성을 동시에 반영[10-11]하고자 한다. 아울러 태양광 시스템의 특성 및 환경 변수를 고려함으로써 예측 모델의 일반화 성능을 더욱 향상시킬 것으로 기대된다.

ACKNOWLEDGMENT

이 논문은 2025년도 정부(과학기술정보통신부) 및 정보통신기획평가원의 지역지능화혁신인재 양성사업(IITP-2025-RS-2022-00156360)과 2025년도 교육부 및 서울특별시의 재원으로서 서울RISE센터의 지원을 받아 수행된 결과물임(2025-RISE-01-020-04)

참 고 문 현

- [1] Korea Power Exchange(KPX), Operational Guidelines for Renewables Energy Forecasting, 2021
- [2] S.pelland, G. Galanis, G.Kallos, “Solar and photovoltaic forecasting through post-processing of numerical weather predictions,” Solar Energy, vol. 82, no. 10, pp. 1004–1015, 2013
- [3] J. P. Barton, D. B. Infield, “Energy storacte and its use with intermittent renewable energy”, IEEE Transactions on Energy Conversion, vol. 19, no. 2, pp.441–448, 2004
- [4] Y. Wang, W. Xia, C. Kang, “Review of hybrid models for short-term photovoltaic power forecasting”, Renewable and Sustainable Energy Review, vol. 81, pp.158–168, 2018
- [5] H.Lee, J. Park, S. Kim, “Photovoltaic power forecasting using meteorological data from nearby weather stations”, Journal of Electrical Engineering & Technology, vol. 15, no. 3, pp.1231–1240, 2020
- [6] A. Mellit, S. Kalogirou, “Artificial intelligence techniques for photovoltaic applications : A review”, Progress in Energy and Combustion Science, vol. 34, pp.574–632, 2008
- [7] Y.Nam, J. Hur, “Probabilistic photovoltaic power forecasting usign spatial interpolation and Naive Bayes classifier”, IEEE Accesssm vol.6, pp.55338–55348, 2018.
- [8] Goodfellow, I., Bengio, Y., and Courville, A., 2016, Deep Learning, MIT Press, Cambridge, MA.
- [9] Hochreiter, S., and Schmidhuber, J., 1997, “Long short-term memory”, Neural Comput., 9(8), 1735 - 1780.
- [10] Cressie, N., and Huang, H.C., 1999, “Classes of nonseparable, spatio-temporal stationary covariance functions”, J. Am. Stat. Assoc., 94(448), 1330 - 1340.
- [11] De Iaco, S., Myers, D.E., and Posa, D., 2001, “Space - time analysis using a general product - sum model”, Stat. Probab. Lett., 52(1), 21 - 28.