

풍력 단지 내 신규 터빈 입지 결정을 위한 SDWPF 데이터셋 기반 강화학습 접근법

이민정, 허태욱*

과학기술연합대학원대학교, *한국전자통신연구원

mjlee00@ust.ac.kr, *htw398@etri.re.kr

A Reinforcement Learning Framework Based on the SDWPF Dataset for Optimal Placement of New Turbines in Wind Farms

Min Jeong Lee, Tae-Wook Heo*

University of Science and Technology (UST),

*Electronics and Telecommunications Research Institute (ETRI)

요약

풍력 단지에서 신규 터빈의 위치를 결정하는 과정은 후류 효과로 인한 발전 효율 저하 문제 때문에 단순한 격자식 배치만으로는 충분하지 않다. 본 논문은 기존 풍력 단지의 운영 데이터를 활용하여 새로운 풍력 터빈의 최적 입지를 결정하는 강화학습 기반 프레임워크를 제안한다. 후류 효과를 정량적으로 모델링하기 위해 SDWPF 데이터셋을 기반으로 후류 밀도, 상풍 발전량, 상풍 유입 풍속의 세 가지 특성 변수를 산출했다. 이를 LightGBM 모델의 입력으로 사용하여 터빈별 유효 발전량을 예측하는 서러게이트 모델을 구축했으며, 최적 입지 탐색을 위해 Soft Actor-Critic(SAC) 강화학습 알고리즘을 활용했다. 평가 결과, 강화학습이 제안한 신규 좌표는 기존 좌표 대비 예측 발전량이 0.51 kW (0.12%) 증가했으나, 이는 기존 배치가 이미 최적에 가까웠기 때문으로 보이며, 통계적 유의성보다는 기존과 동등한 수준의 입지를 제시하는 방법론으로서의 의의를 갖는다.

I. 서론

기후 변화 대응을 위한 에너지 전환이 가속화되면서 풍력 발전은 핵심적인 청정 에너지원으로 부상하고 있다. 풍력 발전소의 입지 선정은 풍력 자원 지도, 송전망 접근성, 환경 규제 등 복합적인 요소를 고려하는 거시적 관점이 있다. 부지가 확정되면 개별 터빈을 배치하는 미시적 설계 단계로, 후류 효과를 고려해야 한다. 후류 효과는 상류 터빈이 후방의 풍속을 감소시키고 난류를 증가시키며, 이는 후방 터빈의 발전량 감소 및 설비 피로도를 높일 수 있다. 이를 완화하기 위해 기존에는 터빈을 일정한 간격의 격자나 엇갈린 형태로 배열했으나, 이는 변화하는 풍향에 능동적으로 대응하기 어렵고, 터빈 간 거리를 넓히게 되면 부지 면적과 케이블 연결 비용의 증가로 이어져 경제성을 악화시킬 수 있다. 특히 국내의 경우 국토가 좁고 풍력 자원이 특정 지역에 집중되어 제한된 입지 내에서 발전 효율을 극대화해야 하는 제약이 있다.

따라서, 본 논문은 기존 풍력 단지의 운영 데이터를 통해 후류 효과 및 유효 발전량을 예측하고, 강화학습 기반의 시뮬레이션을 통해 제약된 범위 내 신규 터빈의 최적 입지를 결정하는 방법을 제안한다(그림 1).

II. 본론

2.1 SDWPF 데이터셋 기반 전처리

풍력 단지 내 신규 터빈의 최적 입지 선정을 위해 터빈의 위치 좌표가 포함된 Spatial Dynamic Wind Power Forecasting (SDWPF) 데이터셋을 활용한다[1]. SDWPF는 단지 내 134기 터빈의 상대 좌표(x, y)와 지형 고도를 포함하며, 1년간 10분 간격으로 연속 수집된 시계열 형태이다. 각 터빈의 발전·운영 상태(Patv, Pab, Prtv 등), 풍속 정보(Wspd, Wdir), 기상 데이터(Wspd_w, Wdir_w, T2m, Sp, RelH, Tp)를 제공한다.

새로운 위치의 후류 효과를 예측하기 위해 SDWPF 데이터셋을 기반으로 풍력 발전 단지 내 터빈 간의 후류 효과를 정량적으로 모델링한다. 이웃 터빈을 탐색할 영향 반경(R), 주 풍향에서 벗어나는 허용 각도($\pm \Delta \theta$), 거리에 따른 영향력 감소를 조절하는 거리 감쇠 길이(L)를 설정값으로 한다. 각 시간(t)마다 특정 터빈을 후보로 설정하고, 기상관측 풍향 데이터(기상 관례 North=0°)를 단지 내부 좌표(East=0°)에 맞게 변환한다. 변환된 풍향을 기준으로, 설정된 반경(R)과 허용 각도($\pm \Delta \theta$)

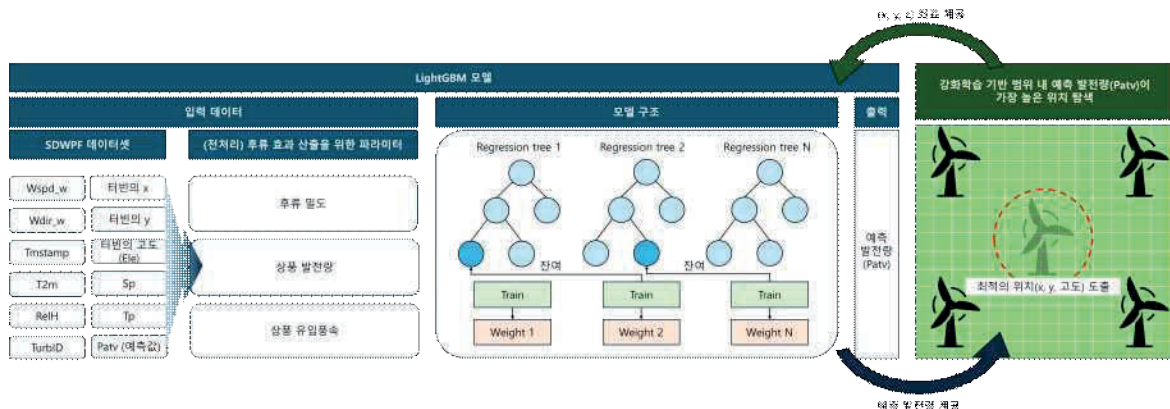


그림 1. 풍력 단지 내의 신규 터빈의 최적 위치를 결정하는 방법에 대한 전체적인 구성도

내에 위치하며 후보 터빈의 바람을 막는 상풍 위치에 있는 이웃 터빈들을 선별한다. 각 이웃 터빈이 후보 터빈에 미치는 영향력은 후보와 이웃 간의 거리(d)를 이용한 가우시안 가중치($w = \exp[-(d/L)^2]$)를 적용하여 거리가 멀수록 영향이 지수적으로 감소하도록 계산한다[2]. 이 가중치를 기반으로 상풍 이웃 터빈의 수와 근접성을 종합적으로 나타낸 후류 밀도, 상풍 터빈들의 실제 발전량을 가중평균한 상풍 발전량, 상풍 터빈으로 유입되는 풍속을 가중 평균한 상풍 유입풍속의 세 가지 후류 특성 변수를 산출한다. 이는 모델의 발전 예측과 강화학습을 통한 최적의 터빈 입지를 선정하는 과정의 신뢰성을 높이기 위해 활용한다.

2.2 발전량 예측을 위한 LightGBM

본 연구는 선행연구[3]에서 제시된 부스팅 기반 모델이 풍력 발전량 예측 성능을 향상시킨 사례를 바탕으로, 부스팅 기법을 활용하여 풍력 발전량을 예측한다. 강화학습 에이전트의 이동에 따른 좌표별 유효 발전량($Patv$)을 반복적으로 예측하기 위한 서러게이트 모델로 Light Gradient Boosting Machine(LightGBM) 모델을 활용한다[4]. 이 모델은 대용량 데이터 처리와 빠른 연산 속도에 최적화되어 있어 강화학습의 서러게이트 모델로 적합하여 선정하였다. LightGBM은 이전 트리의 오차를 보완하며 순차적으로 학습하는 그래디언트 부스팅 프레임워크로서, 최대 손실 감소가 발생하는 노드를 우선적으로 분할하는 리프 중심 트리 분할(leaf-wise) 방식을 채택한다. 또한, Gradient-based One-Side Sampling(GOSS)을 통해 그래디언트가 큰 데이터에 집중하여 샘플 수를 감소시키고, Exclusive Feature Bundling(EFB)를 통해 상호 배타적 특성들을 묶어 차원을 축소하는 알고리즘을 사용한다. 이를 통해 비대칭적이지만 더 빠른 수렴 속도와 높은 예측 성능을 달성할 수 있다. 따라서, SDWPF 데이터셋과 터빈 위치 및 고도, 데이터 전처리를 통해 생성한 후류 효과 파라미터를 입력받아 유효 발전량($Patv$)을 학습한다. 이후, 강화학습 에이전트가 제시하는 좌표에 대한 발전량을 실시간에 가깝게 예측하여 보상으로 사용한다.

2.3 최적의 풍력 터빈 위치를 찾기 위한 강화학습

본 논문에서는 풍력 터빈의 최적 입지 탐색 문제를 해결하기 위해, 연속 행동 공간에서 효율적인 탐색 성능을 보이는 Soft Actor-Critic(SAC) 알고리즘을 활용한다. 강화학습 정책은 다음과 같이 정의한다.

- 상태: 후보 터빈의 정규화된 3차원 좌표, $s_t = [x, y, z] \in [0, 1]^3$
- 행동: 이동 벡터, $a_t = [\Delta x_t, \Delta y_t, \Delta z_t] \in \mathbb{R}^3$
- 상태 전이: $s_{t+1} = \text{clip}(s_t + ka_t)$
- 보상: $r_t = \widehat{Patv}(s_t) - \lambda \max(0, d_{\min} - d_{\text{nearest}}(s_t))$

보상은 사전에 학습된 LightGBM 모델이 추정한 예상 발전량(\widehat{Patv})에서 제약 조건 위반에 대한 페널티를 차감하여 계산된다. 여기서 d_{\min} 은 터빈 간 최소 이격거리, $d_{\text{nearest}}(s)$ 는 후보 위치에서 가장 가까운 기존 터빈까지의 거리, λ 는 페널티의 강도를 조절하는 가중치이다. 이를 통해 에이전트는 정책을 갱신하며, 제약 조건을 만족하는 동시에 발전 잠재력을 극대화하는 최적의 좌표로 수렴하는 방법을 학습한다.

III. 결과

LightGBM 기반 발전량 예측 결과는 전체 테스트 셋에서 MAE 163.61 kW로 나타났다. 이를 바탕으로 강화학습 기반 위치 최적화의 효과를 검




그림 2. 강화학습을 통해 도출한 최적의 좌표 및 터빈의 지리적 분포

증하기 위해, 평가 대상 터빈(TurbID 23)의 데이터는 강화학습의 상태(터빈 위치 정보)에서 제외한 뒤 탐색을 수행하였다. 그 결과, 기존 좌표($x=3346.8, y=4989.9, z=1422.7$)에서의 예측 발전량은 421.97 kW이며, 강화학습이 제안한 신규 좌표($x=2684.7, y=5398.9, z=1422.7$)에서는 예측 발전량이 422.48 kW로 0.51 kW(0.12%)로 증가했다(그림 2 참조). 그러나, 두 위치에서의 국소 예측 오차 추정치(MAE)의 증가 폭이 모델 오차 범위에 비해 현저히 작아 통계적으로 유의한 개선으로 단정하기는 어렵다. 이는 평가 대상 터빈(TurbID 23)의 초기 배치가 이미 공학적으로 거의 최적에 가까워 추가 개선 여지가 제한적이었기 때문으로 해석된다.

IV. 결론

본 연구는 기존 풍력 단지에서 신규 터빈의 좌표를 강화학습으로 탐색하고, LightGBM 모델로 보상을 산출하는 최적화 프레임워크를 제안하였다. 평가 대상 터빈 대비 강화학습이 제안한 좌표의 예측 발전량이 0.51 kW 더 높았으나, 증가 폭이 작아 통계적으로 유의한 향상보다 기존과 동등한 수준의 대안으로 해석할 수 있다. 이는 SDWPF 데이터셋의 현 배치가 이미 최적에 가까워 추가 개선 여지가 제한적이었기 때문일 수 있으며, 상대적으로 비효율적 배치의 경우 더 큰 성능 향상이 기대된다.

ACKNOWLEDGMENT

본 연구는 2025년도 정부(산업통상자원부)의 재원으로 한국산업기술진흥원(KIAT)의 지원을 받아 수행된 연구임(RS-2025-04752996).

참고 문헌

- [1] Zhou, J., Lu, X., et al., "SDWPF: A Dataset for Spatial Dynamic Wind Power Forecasting over a Large Turbine Array," *Scientific Data*, vol. 11, no. 649, 2024.
- [2] Bastankhah, M. and Porte-Agel, F., "A new analytical model for wind-turbine wakes," *Renewable Energy*, vol.70, pp. 116-123, 2014.
- [3] Mingu, K. and Taewook, H., "Improved Wind Power Forecasting for Clean Energy Management Using Clustering and Machine Learning," *Clean Technology*, vol.31, no.3, pp. 182-191, 2025.
- [4] Guolin, K., Qi, M., et. al., "LightGBM: A Highly Efficient Gradient Boosting Decision Tree," *Proceedings of NIPS*, 2017.