

Informer기반 태양광 일일 발전전력 예측 연구

권상협, 임용서, 배성우[†]
한양대학교

Day-ahead forecasting for photovoltaic generation with Informer

Sagnhyeob Kwon, Rongrui Lin, Sungwoo Bae[†]
Hanyang university

ABSTRACT

최근 국내에 태양광 발전시스템은 탄소중립과 지구 온난화 등의 기후 변화 문제를 완화하기 위해 활발히 도입되고 있다. 태양광 발전전력 예측은 전력 시스템의 안정도와 신뢰도를 보장하기 위해 필수적으로 이루어져야 한다. 그러나, 실제 태양광 발전시스템에서 수집된 Advanced metering Infrastructure (AMI) 데이터는 이상 데이터가 포함되므로 예측 모델 학습전에 전처리 과정이 필요하다. 또한, 태양광 발전 시스템은 기상 조건에 따라 발전전력이 급변하므로 불확실성과 변동성이 높아 예측 성능을 확보하기 어렵다. 따라서, 본 논문은 태양광 발전전력의 데이터의 전처리과정과 Informer 모델을 활용한 Day-ahead 예측 방법을 제안한다. 제안한 방법은 기존 Transformer 모델과 비교하여 예측과 연산 성능 개선을 입증하였다.

1. 서 론

국내에서는 탈탄소화를 위해 태양광 발전 설비가 활발히 도입되고 있다. 태양광 발전 설비 생산된 에너지량이 2023년 기준 25,842,357MWh에 달하여 국내 전체 발전량의 13.4%를 차지하고 있다. 또한, 2024년 5월 기준으로 태양광 발전 시설은 24,174MW가 설치됨에 따라 금년에는 더 많은 태양광 발전 이루어질 것으로 예상된다^[1]. 그러나, 태양광 발전 설비에 설치된 AMI 데이터는 설비 유지보수, 통신 오류 등의 원인으로 이상치 및 결측치와 같은 이상데이터가 발생한다. 또한, 태양광 발전전력은 기상 조건에 따라 발전 전력이 결정되므로 변동성과 불확실성이 높다. 이러한 이유로 태양광발전 예측 성능을 확보하는 것은 상당히 어렵다.

본 논문은 AMI데이터의 전처리과 Informer^[2]기반 예측 모델을 제안한다. 이상치와 결측치가 포함된 태양광 발전전력 원본 데이터는 일사량계에서 측정된 일사량 데이터를 활용하여 데이터를 정제하였다. 태양광 발전전력의 비선형 패턴 학습 성능과 연산 부담을 최소화하기 위한 *probSparse* self-attention과 *distilling mechanism*이 포함된 Informer 모델을 채택하였다. 제안한 모델은 소규모 마이크로그리드의 태양광발전 시스템의 발전전력을 예측하였으며, 벤치마크와 비교하여 높은 성능을 보여주었다.

2. Day-ahead 태양광 발전 예측

2.1 태양광 발전전력 데이터 수집 및 전처리

데이터베이스에 저장된 원본 데이터는 175kW규모 태양광 발전 시스템의 AMI와 발전단지 부근 일사량계에서 수집된 데이터이다. 원본 데이터는 설비의 유지보수나 계측 및 통신 오류로 인해 이상 데이터가 발생된다. 원본 데이터에서 Interquartile Range (IQR)의 특이치 상한과 하한 경계를 벗어난 값을 이상치로 처리하였다. 상한 경계와 하한 경계를 구하는 공식은 다음과 같다.

$$UpperBound = Q3 + 1.5 \times IQR \quad (1)$$

$$LowerBound = Q1 - 1.5 \times IQR \quad (2)$$

여기서, $Q1$ 과 $Q3$ 는 데이터의 하위 25%와 상위 25%를 의미하며, IQR 는 $Q3 - Q1$ 로 표현되어질 수 있다.

이상 데이터는 발생한 기간에 따라 2가지 방식으로 보간하였다. 단기간 이상 데이터는 일반적으로 활용되는 선형 보간 방법을 채택하였으며, 장기 이상데이터는 태양광 발전전력과의 피어슨 상관계수가 0.89인 일사량 데이터를 기반으로 보간하였다. 장기 이상데이터 보간 방식은 계측된 일사량 데이터의 Min-Max 정규화를 한 후 태양광 정격 용량을 곱하여 데이터를 정제하였다. 따라서, 데이터 전처리 과정을 통해 장기간 데이터 손실이 발생한 경우라도 예측 모델이 태양광 발전전력 패턴 학습이 가능하도록 하였다.

2.2 Informer 모델

기존 Transformer^[3]는 기존 RNN 기반 인공지능 모델의 장기 패턴에 대한 기억 손실 문제를 완화하였지만, Self-attention의 quadratic 연산으로 상당한 메모리 사용과 연산량이 요구된다. Informer는 확률 이론을 기반으로 의미 있는 Attention Score 선별 방법과 Distilling mechanism을 활용하여 연산량 및 메모리 할당을 $O(L^2)$ 을 $O(L \ln(L))$ 만큼 줄였다.

기존 Self-attention은 다음과 같이 표현되어질 수 있다^[2].

$$Attention(Q, K, V) = softmax(QK^T / \sqrt{d})V \quad (3)$$

여기서, Q , K , V 는 keys, query, value를 의미하며, Attention mechanism의 입력이다. 여기서, self-attention에서 m번째 query 연산을 kernel smoother 확률형태로 다시 표현할 수 있다^[3].

$$Attention(q_m, K, V) = \sum_n \frac{k(q_m, k_n)}{\sum_l k(q_m, k_l)} v_n = \mathbb{E}_{p(k|q_m)} [v_n] \quad (4)$$

여기서, n번째 key에 대한 attention score는 $p(k|q_m)$ 를 의미하며, $k(q_m, k_n) / \sum_l k(q_m, k_l)$ 로 계산되어진다. 또한, k 는 비대칭 지수 커널이다. self-attention 출력은 확률 $p(k|q_m)$ 와 n번째 value 행렬 곱으로 도출된다. Attention score는 롱 테일 분포를 따르므로, Attention score 의미있는 key와 query값은 매우 적다^[3]. 따라서, 콜백-라이블러 발산을 활용하여 top-u queries를 도출할 수 있다.

$$M(q_m, K) = \ln \sum_{n=1}^{L_K} e^{\frac{q_m k_n^T}{\sqrt{d}}} - \frac{1}{L_K} \sum_{n=1}^{L_K} \frac{q_m k_n^T}{\sqrt{d}} - \ln L_K \quad (5)$$

식(5)를 활용하면, 기존 self-attention을 *probparse* self-attention으로 재정의 할 수 있다.

$$Attention(Q, K, V) = softmax(\bar{Q}K^T / \sqrt{d})V \quad (6)$$

여기서, \bar{Q} 는 희소 행렬이며, top-u queries를 포함한다. 또한, value 행렬에 대한 연산을 더 줄이기 위해 Convolution neural network(CNN)을 활용한 distilling mechanism을 채택하였다. 다음과 같은 식으로 표현되어진다.

$$X'_{j+1} = MaxPool ELU Conv1d [X'_j]_{AB} \quad (7)$$

여기서, X'_{j+1} 은 u번째 층에서 distilling 절차를 하고 난 뒤의 출력이다. *Conv1d*는 1차원 convolution filter이며, ELU는 활성화함수이다. 활성화함수에서 나온 출력의 Max값만을 추출하여 *Probparse* self-attention의 연산을 최소화할 수 있다.

3. 실험

표 1 Informer 하이퍼파라미터

Table 1 The hyperparameters for informer

| 하이퍼파라미터 | 탐색 격자 |
|--------------|------------------------|
| 인코더 층 수 | [1,2,3,4,5] |
| 디코더 층 수 | [1,2,3,4,5] |
| 임베딩 차원수 | [256, 512, 1024, 2048] |
| Multi-Head 수 | [2,4,8,16] |

3.1 모델 하이퍼파라미터 및 학습

태양광 발전전력 예측을 위한 Informer모델의 하이퍼파라미터 중 성능과 직접적인 관련이 있는 것은 인코더 층수, 디코더 층수, 임베딩 차원수, Multi-head 수이다. 해당 하이퍼파라미터 선별은 그리드서치를 활용하였으며 표1에서 탐색 그리드의 리스트([·])와 선정된 값(볼드체)을 확인할 수 있다. Multi-head와 임베딩 차원수는 informer모델 내의 구조에서 차원수를 맞추기 위해 나누었을 때 나머지가 0이 되는 2배수로 탐색하는 격자를 선정하였다. 제안한 모델의 훈련을 위한 최적화 알고리즘은 Adam을 사용하였으며, 학습률은 0.0001로 학습을 수행하였다. 모델의 손실함수는 MSE를 활용하였으며, 256 배치사이즈를 사용하였다. 모든 실험은 24GB Nvidia GeForce RTX 3090 GPU 4개를 사용하였으며, 모든 환경은 pytorch 2.2로 개발하였다. 전체 데이터의 훈련 60%, 검증 20%, 테스트 20%비율로 구분하여 모델의 성능평가를

표 2 태양광 발전전력 예측 성능평가 테스트 결과

Table 2 The results of performance for photovoltaic generation

| 모델 | 지표 | |
|-------------|----------|---------|
| | nRMSE(%) | MAE(kW) |
| Transformer | 19.78 | 21.83 |
| Informer | 16.72 | 16.94 |




그림1 Informer 태양광발전 예측 결과

Fig.1 The forecasting photovoltaic generation with informer

하였다.

3.2 결과

제안한 모델에 대한 태양광 발전전력 예측의 우수한 성능을 입증하기 위해 Transformer 모델을 벤치마크로 선정하여 비교분석을 하였다. 총 하루 5분 단위 총 288개의 하루 태양광 발전전력을 예측하였다. 표2은 Transformer와 Informer의 예측결과를 나타내며, Informer가 Transformer 보다 nRMSE 3.03%, MAE 4.89kW 만큼 예측 결과가 개선되었다. 그림2를 참조하면, 주황색 그래프는 AMI에서 측정된 5분 단위 실제 태양광 발전전력이며, 파란색은 Informer를 활용한 예측 결과이며 예측 성능이 우수한 것을 확인할 수 있다.

4. 결론

본 논문은 소규모 마이크로그리드 내의 175kW 규모 태양광 발전 전력에 대한 데이터 전처리 과정과 Informer 예측 모델을 제안하였다. 태양광 발전 전력의 원본 데이터를 발생 시간에 따라 이상치와 결측치를 전처리하였다. 단기 이상 데이터는 선형 보간을 활용하였고, 장기 이상 데이터는 일사량 데이터를 활용하여 보간했다. 태양광 발전 전력 예측 모델은 Informer로 개발되었으며, 장기 기억 손실을 방지하고 연산 효율을 개선하였다. 제안된 모델은 기존 모델과 비교하여 우수한 예측 성능을 보여주었다.

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20212020800090)

참고 문헌

- [1] 재생에너지클라우드플랫폼, “https://recloud.energy.or.kr/main/main.do”[Online]. Available: https://www.iea.org/reports/global-ev-outlook-2023
- [2] H. Zhou et al., “Informer: Beyond efficient transformer for long sequence time-series forecasting,” in *Proc. AAAI Conf. Artif. Intell.*, 2021, vol. 35, no. 12, pp. 11106–11115.
- [3] A. Vaswani et al., “Attention is all you need,” in *Proc. Adv. Neural Inf. Process. Syst.*, vol. 30, 2017, pp. 1–11.