

하이브리드 모델을 이용하여 중단기 태양발전량 예측

Mid- and Short-term Power Generation Forecasting using Hybrid Model

손남례*

Nam-Rye Son*

〈Abstract〉

Solar energy forecasting is essential for (1) power system planning, management, and operation, requiring accurate predictions. It is crucial for (2) ensuring a continuous and sustainable power supply to customers and (3) optimizing the operation and control of renewable energy systems and the electricity market. Recently, research has been focusing on developing solar energy forecasting models that can provide daily plans for power usage and production and be verified in the electricity market. In these prediction models, various data, including solar energy generation and climate data, are chosen to be utilized in the forecasting process. The most commonly used climate data (such as temperature, relative humidity, precipitation, solar radiation, and wind speed) significantly influence the fluctuations in solar energy generation based on weather conditions. Therefore, this paper proposes a hybrid forecasting model by combining the strengths of the Prophet model and the GRU model, which exhibits excellent predictive performance. The forecasting periods for solar energy generation are tested in short-term (2 days, 7 days) and medium-term (15 days, 30 days) scenarios. The experimental results demonstrate that the proposed approach outperforms the conventional Prophet model by more than twice in terms of Root Mean Square Error (RMSE) and surpasses the modified GRU model by more than 1.5 times, showcasing superior performance.

Keywords : Power Consumption Forecasting, BEMS, PROPHET, LSTM, GRU, Meteorological Data

* 정희원, 교신저자, 전남대학교 소프트웨어중심대학사업단, 부교수 * Software Centered University Project Group
E-mail: nrson72@gmail.ac.kr

1. 서론

에너지 위기, 대기 오염, 지구 온난화 및 기타 환경 문제는 재생 에너지 개발이 활발히 연구 중에 있으며 2030년까지 에너지 소비의 약 40%를 차지할 것으로 예상된다[1]. 태양광발전은 태양광 모듈을 이용하여 태양에너지를 전기에너지로 직접 변환시키는 발전장치를 말한다. 환경오염이 적고, 대기 및 수자원의 무공해, 소음공해가 없으며, 현지 여건에 적응할 수 있는 능력, 낮은 설치비용, 현장소모 등의 장점을 지닌 종합적인 에너지이용 공법이다. 전력망에 연결될 때, 발전과 소비의 공존을 달성할 수 있으며 현재 가장 유망한 PV 기술 중 하나이다. Rethink Energy 데이터에 따르면 2022년 첫 9개월동안 전 세계에 설치된 태양 에너지 용량은 전년 대비 37.8% 증가한 54GW 증가했고, 총 설치 용량은 약 142.5GW이다. 예측에 따르면 연간 설치 용량은 222GW에 이를 것으로 보인다. 유럽 태양광 협회 SPE의 최신 보고서에 따르면 2022년 EU 27개국의 신규 장치 설치 용량은 41.4GW로 전년 대비 28.1GW 순증가하여 전년 대비 47GW 증가했다. 2022년까지 누적 설치 용량은 208.9GW에 이를 것으로 예상된다. 중국 국가 에너지국이 발표한 통계 데이터에 따르면 2022년 신규 설치 전력 용량은 87.41GW이며 2022년까지 누적 설치 전력 용량은 396.261GW에 달했다[2][3].

발전량 예측은 유럽과 미국에 태양광축소가 조기에 많이 설치되고 첨단 기술과 장비의 지원이 많고 충분한 데이터가 축적되어 매우 일찍 연구가 이루어졌다. 주요 작업은 예측 정확도를 향상시키기 위해 다양한 예측 모델을 사용하는 것과 관련이 있으며 작업의 일부는 기존 방법을 요약하거나 경제적 이점을 분석하는 것이다. 태양광 발전량 예측을 실현하는 방법은 주로 물리학과 통계학의 전통적인

예측 방법, 머신 러닝, 최적화 알고리즘, 딥 러닝을 이용한 새로운 예측 방법과 하이브리드 모델로 구분된다[4]-[19]. 태양광발전량예측은 기간에 따라 단기, 중기, 장기로 구분한다[4]. 단기 태양광발전량예측은 시간 단위 또는 하루에서 몇 주 사이의 예측으로 지수 평활법(Exponential Smoothing)[5], ARIMA(Auto Regressive Integrated Moving Average)[6] 등 알고리즘이 있다. 중기 태양광발전량예측은 몇 주에서 몇 개월 사이의 예측하는 방법으로 기상 데이터, 이벤트 정보, 경제 지표 등 다양한 변수를 활용하여 태양광발전량을 예측한다. 선형회귀, 다중회귀[7], 신경망[8], 딥러닝[9], LSTM(Long Short term Memory)[10] 등 다양한 알고리즘이 있다. 장기 태양광발전량예측은 3개월에서 1년까지의 예측하는 방법으로 단기 및 중기보다 많은 변수와 시스템 요소를 고려해야 하는 단점을 가지고 있다. 장기 전력 예측알고리즘은 시계열분석, ARIMA, 앙상블 기법이 있고 장기 태양광발전량의 추세와 패턴을 예측하는데 도움이 될 수 있다.

ARIMA는 단기예측에 효과적이지만 계절성이나 비정상성이 있는 데이터에는 적용하기 어렵고, 장기적인 패턴을 예측하기 어려운 단점을 가지고 있다. 지수평활법은 단기예측에 유용하지만 장기적인 패턴을 예측하기 어렵고, 다른 요인을 고려하기 어려운 단점을 가지고 있다. Prophet은 중기 예측에 적합하며, 계절성과 이벤트를 처리할 수 있지만 장기적인 트렌드를 예측하기 어려운 단점을 가지고 있다. LSTM은 시계열 데이터의 장기적인 의존성을 학습하여 장기예측에 적합하지만 데이터의 양과 품질에 민감하고 학습 및 예측에 많은 계산 자원이 필요한 단점을 가지고 있다[11]-[13].

최근 태양광발전량 예측 알고리즘은 데이터의 특성과 예측 목표에 따라 여러 알고리즘을 조합한 하이브리드 모델 연구가 진행되고 있다[14]-[19]. Prophet과 LSTM을 조합하여 Prophet을 사용하

여 단기 예측을 수행하고, LSTM을 사용하여 장기 예측을 수행하여 전력수요예측에 향상된 정확성과 성능을 보여준다[14][15]. ARIAM와 XGBoost를 조합하여 태양광발전량의 단기예측을 제안했다[16][17].

ARIMA와 LSTM을 조합하여 ARIMA를 사용하여 시계열 데이터의 트렌드와 계절성을 모델링하고, LSTM을 사용하여 예측 성능을 개선한 연구이다[18][19].

본 논문은 장기예측에 적합한 GRU과 계절성 및 이벤트 처리에 적합한 Prophet 모델을 혼합하여 중단기 태양광발전량예측 방법을 다음과 같이 제안한다. (1) 전라남도 나주지역에 있는 석유화학 W 회사의 태양광발전량데이터 및 기후데이터를 수집 및 전처리 한다. (2) 전처리된 데이터는 계절성과 이벤트 처리를 위하여 1단계에서 Prophet 모델을 제안하여 예측하였다. (3) 2단계에서는 9개 다변량 데이터를 GRU에서 실험을 하였다. 즉, 다변량 데이터 9개는 기후 데이터 8개와 1단계에서 제안한 Prophet 모델에서 예측한 데이터와 실측치 데이터 간 잔차를 이용하여 15분 간격으로 전력생산량을 예측하였다. (4) 전력생산량을 예측할 때 단기(2일, 7일)와 중기(15일, 30일)로 나눠서 실험하였다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구로 Prophet 모델 및 GRU에 대하여 기술을 한다. 3장에서는 기존 Prophet 모델의 문제점과 해결방법을 설명한다. 4장에서는 제안한 방법에 대한 알고리즘 및 실험결과를 설명한다. 마지막으로 5장에서는 결론으로 맺음을 한다.

2. 관련연구

2.1 Prophet Model

Prophet 모델은 Facebook에서 개발된 개방형

소스의 시계열 예측 라이브러리이다[20]. Prophet은 시간에 따라 변화하는 시계열 데이터를 예측하기 위한 강력한 도구로 마케팅 및 광고, 수요예측, 에너지예측, 재무예측 등 다양한 분야에서 널리 사용되고 있다. Prophet 모델은 식 (1)과 같이 트렌드(growth), 계절성(seasonality), 휴일(holidays) 3가지로 구성되어 있다.

$$y(t)=g(t)+s(t)+h(t)+\epsilon(t) \quad (1)$$

식 (1)에서 $g(t)$ 는 비주기적 변화를 반영하는 추세 함수, $s(t)$ 는 주기적인 변화(ex, 주간/연간), $h(t)$ 는 휴일(불규칙 이벤트)의 영향력이고, $\epsilon(t)$ 는 오차이다. prophet 모델은 다른 시계열 모형과 달리 시간에 종속적인 구조를 가지지 않고 curve-fitting으로 예측 문제를 해결하는 장점을 가지고 있다.

Fig. 1는 본 논문에서 2018년 7월 1일부터 2019년 11월 30일까지 수집한 W회사의 전력생산량이다.

Fig. 2~Fig. 3은 1년(2018년 7월~2019년 6월)간 학습데이터에 Holiday effect만 고려하여 Prophet 모델을 적용한 예측 결과이다.

Fig. 2에서 파란색 선은 모델이 예측한 값이고, 검정색 점들은 실제 데이터 값이다. Fig. 3 피팅




Fig. 1 Power generation of W Company (2018 .7~ 2019.11.)

된 모델의 컴포넌트(Trend, Yearly, Weekly, Daily)들을 시각한 결과이다.

Fig. 3에서 Trend는 월별로 큰 변화가 없는 추세이고, Holidays는 발전량 오차가 간헐적으로 크게 보이고, Weekly는 월요일에서 금요일까지 전력생산량이 발생하고 주말에는 전력생산량이 발생




Fig. 2 Predictive simulation using the Prophet model

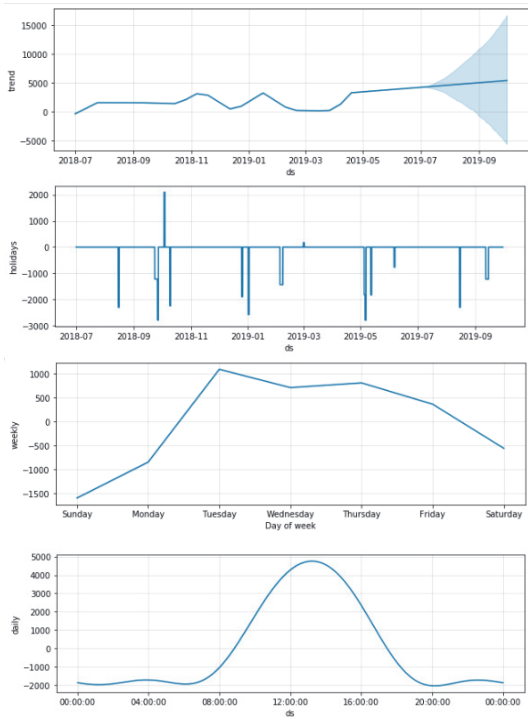


Fig. 3 Components of the prophet model

하지 않았다. 마지막으로 Daily는 일조량 시간대와 맞게 대부분 오전 8시부터 오후 8시까지 태양 광발전량이 발생하고, 나머지 시간대는 태양광발전량이 발생하지 않는 추세이다.

2.2 GRU(Gated Recurrent Unit)

GRU는 순환 신경망(RNN)의 한 종류로, 시퀀스 데이터 처리에 사용되는 모델이다[21]. GRU는 LSTM과 비슷한 기능을 제공하지만 Fig. 4와 같이 LSTM보다 간단한 구조이다. GRU는 시퀀스 데이터의 장기적인 의존성을 학습하면서 기울기 소실 (vanishing gradient) 문제를 해결하고, 계산 비용을 줄이는 장점이 있다. GRU의 구성 요소는 업데이트 게이트(Update Gate), 리셋 게이트(Reset Gate), 은닉 상태(Hidden State)이고, 식 (2)는 GRU의 수식이다.

식 (2)에서 r_t 는 리셋 게이트이고, z_t 는 업데이트 게이트이다. x_t 는 현재 시점의 입력값, W_z 와 W_r 는 각각 업데이트 및 리셋 가중치이다.

$$\begin{aligned}
 z_t &= \sigma(W_z \cdot [h_{t-1}, x_t]) \\
 r_t &= \sigma(W_r \cdot [h_{t-1}, x_t]) \\
 \tilde{h}_t &= \tanh(W \cdot [r_t * h_{t-1}, x_t]) \\
 h_t &= (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t
 \end{aligned}
 \tag{2}$$

식 (2)에서 업데이트 게이트(r_t)는 현재 입력과




Fig. 4 GRU model

이전 시점의 은닉 상태를 기반으로 얼마나 많은 정보를 기억할지 결정한다. 리셋 게이트(z_t)는 현재 입력과 이전 시점의 은닉 상태를 기반으로 얼마나 많은 과거 정보를 잊을지 결정한다. 은닉 상태(h_t)는 이전 시점의 은닉 상태와 현재 입력을 기반으로 새로운 은닉 상태를 계산한다.

3. 문제정의 및 해결방안

3.1 Prophet 모델의 문제점

Prophet의 장점은 계절성 및 이벤트(휴일, 공휴일)를 반영하여 예측하는 모델이다. 하지만 Fig. 5에서 2019년 9월1일부터 31일까지 Prophet 모델(yhat)을 적용한 결과, 추석연휴 4일동안(9월12일~9월15일) 실측치(y)는 제로에 가깝지만 Prophet 모델을 적용한 결과는 정확히 예측하지 못한 단점이 있다. 따라서 Prophet 모델 적용시 holiday 정보(기간, 이름)와 휴일 전후에도 전력생산량에 영향을 미치므로 해당일만큼 파라미터 설정이 필요하고, trend의 유연성 조절, 년 계절성(yearly seasonality) 등 전력생산량 예측에 맞게 적절한 파라미터를 설정할 필요가 있다.

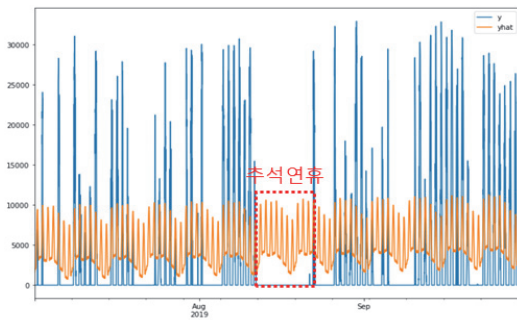


Fig. 5 Performanc comparison of conventional Prophet and observed value (2019.7~9)

3.2 해결방안

Fig. 6은 2019년 7월 2일(15분 단위)에 대한 Prophet 모델(Prophet)과 실측치(y)에 대한 오차이다. 오차를 해결하기 위하여 건물의 전력생산량에 영향을 미치는 기후 데이터를 사용하여 중단기 예측에 적합한 GRU를 적용한다.

본 논문에서는 수집된 전력생산량과 기후데이터를 이용하여 GRU을 수행할 경우 공휴일 및 이벤트에 대한 정보를 처리하지 못한 단점을 가지고 있다. 따라서 장기예측은 공휴일 및 이벤트 처리에 적합한 Prophet을 적용하였고, 단기예측은 GRU을 혼합하여 제안한다.




Fig. 6 Error between Prophet model and observed value (2019. 7. 2)

4. 제안한 방법

4.1 데이터 수집 및 전처리

4.1.1 태양광발전시스템 설치 장소 및 정보

본 논문에서는 제안한 방법의 유용성을 검증하기 위하여 Table 1과 같이 전라남도 나주 W회사의 건물에 대한 태양광발전시스템 설치장소 및 세

Table 1. Solar power generation system installation location and information

번호	구분	내용
1	위치	전라남도 나주시
2	주사용 목적	자가 태양광발전량
3	건물면적	3동 합계 600평
4	건물층수	공장동 지상1층, 기타 1동
5	건물구조	H빔
6	외벽	샌드위치 패널
7	PV시스템 용량	50KW
8	ESS	PCS: 100kW, 배터리: 200kW

부 정보이다. 건물 주사용 목적은 자가 태양광발전량, 건물면적은 3개동 합계 600평(1983m²)이고, 건물구조는 H빔, 외벽은 샌드위치패널, PV시스템용량은 50KW, PCS는 100kW, 배터리는 200kW이다.

4.1.2 전력 데이터 및 기후 데이터 수집

본 논문에서 사용하는 전력생산량 데이터는 전라남도 나주 W회사(석유화학)의 2018년 7월 1일부터 2019년 9월 31일까지 15분 데이터(전력생산량)를 수집하였다. Workalendar 패키지를 이용하여 한국 휴일 데이터 생성(대체휴일, 선거일, 명절 등) 하였고, 기상청 기상자료개방포털사이트¹⁾에 접속하여 실제 위치(나주)에서의 1시간 간격으로 기후 데이터(시간, 분, 강수, 기온, 풍향, 풍속, 습도, 해면기압)를 수집하였다. 기존 전력생산량에 가장 중요한 기후데이터인 강수량(rain, rain15, rainday), 온도, 풍속, 습도, 일조량, 운량만 선택하였다[22].

4.1.3 데이터 전처리

전력데이터(15분)와 기후데이터(1시간)의 시간 불일치로 기후데이터는 선형보간법을 이용하여 15분 간격으로 데이터를 resampling하여 전력데이터와 시간을 일치시킨다. 또한 전력 및 기후데이

터의 결측치는 0값으로 대체한다. 아웃라이어의 영향을 최소화하는 식 (3)과 같이 RobustScaler를 이용하여 데이터의 scale을 정규화한다.

$$\hat{x} = \frac{x_i - x_{med}}{x_{75} - x_{25}} \quad (3)$$

식 (3)에서 x_i 는 실제값이고, x_{med} 는 데이터 중앙값이고, x_{75} 와 x_{25} 는 각각 사분위 75%와 25%이다.

4.2 제안한 혼합형 예측 알고리즘(2단계)

4.2.1 1단계: 제안한 Prophet 모델

본 논문에서 실험한 학습데이터는 2018년 7월부터 2019년 5월까지 수집한 전력생산량 데이터이다. 2018년~2019년까지 공휴일 및 대체휴일(선거일, 명절) 등을 반영하여 전력생산량의 정확도를 높였다. 즉, Prophet 모델 적용시 Trend (change point_prior_scale), holiday effect (holidays, holiday_prior_scale), 년 계절성 (yearly_seasonality)를 적용하여 시뮬레이션하였다. 시뮬레이션 결과는 Fig. 7과 같고, 실측치와 예측치의 정확도를 위하여 식 (4)와 같이 상관계수(Correlation Coefficient)를 사용하였다.

$$r(X, Y) = \frac{1}{n} \sum_{i=1}^n \frac{(x_i - \bar{x})(y_i - \bar{y})}{\sigma_x \sigma_y} \quad (4)$$

식 (4)에서 \bar{x} 와 \bar{y} 는 각각 X와 Y의 평균, σ_x 와 σ_y 는 각각 X와 Y의 표준편차, n는 데이터 개수이다.

이때 전력생산량 예측치와 실측치의 장기(1년) 및 단기(2일간) 상관계수는 각각 0.67과 0.87이다. 즉, 수정한 Prophet 모델을 이용하여 장기로 전력생산량을 예측할 경우 오류가 높은 단점이 있다.




Fig. 7 Components of the modified Prophet model

하지만 단기로 전력생산량을 예측할 경우 상관계수는 0.87로 예측 기간이 장기보다 우수하였다. 따라서 단기로 전력생산량을 예측할 때 수정한 Prophet 모델을 사용하였다.

4.2.2 2단계: 제안한 GRU

Fig. 6과 같이 Prophet의 예측치와 실측치의 오차를 줄이기 위하여 Fig. 8와 같이 GRU를 제안




Fig. 8 Proposed GRU model

한다. 즉, 입력데이터는 다변수로 기후데이터인 강수량(rain, rain15, rainday), 온도, 풍속, 습도, 일조량, 운량와 잔차(1단계에서 Prophet 모델의 예측치와 실측치의 차이) 총 9개이다. Fig. 8에서 $x_{1-t-1} \sim x_{8-t-1}$ 는 각각 이전 시간(t-1)의 강수량(rain, rain15, rainday), 온도, 풍속, 습도, 일조량, 운량이고, x_{9-t-1} 는 잔차이다.

기존 예측모델인 GRU는 태양광발전량 값을 예측할 때 전체의 값을 대상으로 예측을 한다. 본 논문에서는 장기추세로(년, 월 단위) 예측치와 실측치의 잔차를 GRU에 적용함으로써 식 (4)와 같이 전력생산량을 예측하여 값의 오차율을 낮춘다. 식 (5)에서 *Residual*는 잔차이고, *Prophet_{pred}*는 기존 Prophet 모델의 예측치이고, *y*는 실측치이다.

$$Residual = Prophet_{pred} - y \quad (5)$$

GRU 학습과 검증데이터는 동일한 데이터를 사용하였다. GRU의 입력층은 9개로 기후 데이터 8개인 강수량(rain, rain15, rainday), 온도, 풍속, 습도, 일조량, 운량와 잔차 1개로 구성하였고, 은닉층은 9개, 초기학습 속도는 0.005, 최대 반복 횟수는 50,000, 손실함수는 MSE(Mean Square Error), Optimizer는 ADAM(Adaptive Moment Estimation)를 사용했다.

4.2.3 학습 및 테스트 데이터

학습데이터(2018.07.01~2019.06.31)와 테스트

데이터(2019.07.01~2019.09.31)는 각각 75%와 25%으로 나누어 실험하였다.

5. 실험결과

Table 2는 Prophet, GRU, 제안한 방법의 성능 비교이다. Prophet 모델은 1단계에서 제안한 방법을 사용하였고, GRU는 총 9개(기후데이터 8개와 실측치 1개)에 대한 GRU 시뮬레이션이고, 제안한 방법은 1단계와 2단계를 혼합한 방법이다. 이때 사용한 성능 평가방법은 상관계수와 RMSE(Root Mean Square Error) 방법을 채택하였다.

Prophet 모델의 상관계수는 예측기간이 길수록 낮았지만, GRU 및 제안한 방법의 상관계수는 예측기간과 관계없이 Prophet 모델보다 높았다. Prophet 모델의 RMSE는 GRU보다 2배 정도 높았고, 제안한 방법보다는 2~3배보다 높았다. 또한 GRU의 RMSE는 제안한 방법보다 1.5~2배 이상 높았다. 따라서 제안한 방법이 Prophet 모델이나 GRU보다 성능이 우수하였다.

Fig. 9는 Fig. 12는 각각 2일간(2019년 7월1일~ 7월2일), 7일간(2019년 8월1일~8월7일), 15

Table 2. Performance comparison of conventional Prophet, GRU, and proposed method

기간	방법	Prophet	GRU	제안한 방법
2일 (7/1~7/2)	상관계수	0.39	0.91	0.95
	RMSE	5765.38	2208.82	1588.59
7일 (8/1~8/7)	상관계수	0.69	0.95	0.95
	RMSE	6393.15	2579.23	2510.73
15일 (8/15~8/30)	상관계수	0.47	0.95	0.96
	RMSE	6141.05	2045.46	1756.73
30일 (9/1~9/30)	상관계수	0.67	0.96	0.96
	RMSE	6601.82	2356.95	2227.31

일(2019년 8월15일~8월30일), 30일간(2019년 9월1일~9월30일) 단기 전력생산량 예측 비교이다.

이때 y(실측치)는 측정된 기간안에 측정된 전력 생산량이고, Prophet은 변형된 Prophet 모델이고,




Fig. 9 Comparison of 2-day power generation prediction




Fig. 10 Comparison of 7-day power generation prediction




Fig. 11 Comparison of 15-day power generation prediction




Fig. 12 Comparison of 30-day power generation prediction

GRU은 기후 데이터와 실측치를 가지고 예측한 값이다. 마지막으로 Proposed는 제안한 전력생산량의 예측치이다.

Fig. 9~Fig. 12에서 제안한 방법 및 GRU은 실측치(y)와 거의 유사하지만 Prophet 모델은 실측치(y)와 높은 오차를 보여준다. GRU는 “E” 부분과 같이 간헐적으로 예측치 오차가 높았다. GRU의 예측치 오차가 높은 이유는 공휴일 또는 이벤트(대체휴일, 명절, 휴가)가 연속적으로 발생한 다음날 정확히 발생하지 못한 단점을 가지고 있다. 하지만 제안한 방법은 실측치(y)와 거의 유사하게 예측하였다.

6. 결론

제안된 하이브리드 모델은 정확한 태양 에너지 발전 예측을 제공하여 전력 시스템 계획, 관리 및 운영에 유용할 뿐만 아니라 고객에게 지속적이고 지속 가능한 전력 공급을 보장할 수 있다. 또한 최적화 기능은 재생 가능 에너지 시스템과 전력 시장의 효과적인 운영 및 제어에 기여할 수 있다. 본 논문은 태양광발전량을 예측하기 위하여 Prophet 모델과 GRU를 조합하여 단기(2일, 7일)와 중기(15일, 30일)로 예측 알고리즘을 제안하였다. 제안한 알고리즘은 기존 Prophet 모델 및 GRU보다 우수한 성능을 보여준다.

참고문헌

- [1] International Renewable Energy Agency. Renewable Capacity Statistics; International Renewable Energy Agency: Masdar City, United Arab Emirates, 2020.
- [2] <https://www.letsrethinkenergy.com/>
- [3] G. Grazioli, S. Chlela, S. Selosse, and N. Maïzi, N., “The Multi-Facets of Increasing the Renewable Energy Integration in Power Systems,” *Energies* Vol.15, No. 6795, 2022.
- [4] B. Xue., and J. Keng., “Dynamic transverse correction method of middle and long term energy forecasting based on statistic of forecasting errors,” In *Proceedings of the Conference on Power and Energy IPEC, Ho Chi Minh City, Vietnam*, pp. 253–256, 2012.
- [5] Brown, R.G., “Smoothing Forecasting and Prediction of Discrete Time Series,” Prentice-Hall, Englewood Cliffs, NJ, USA, 1963.
- [6] Y. Ohtsuka, T. Oga, and K. Kakamu, “Forecasting electricity demand in Japan: A Bayesian spatial autoregressive ARMA approach,” *Comp. Stat. Data Anal.*, No.54, pp.2721–2735, 2010.
- [7] C.E. Holt, “Forecasting Seasonal and Trends by Exponentially Weighted Average,” *Carnegie Institute of Technology, Pittsburgh, PA, USA*, 1957.
- [8] S.A. Kalogirou, C.C. Neocleous, C.C. Schizas, “Building heating load estimation using artificial neural networks,” In *Proceedings of the 17th International Conference on Parallel Architectures and Compilation Techniques, San Francisco, CA, USA*, 10–14 November 1997.
- [9] A. Bagnasco, F. Fresi, M. Saviozzi, F. Silvestro, A. Vinci, “Electrical consumption forecasting in hospital facilities: An application case,” *Energy Build*, No.103, pp.261–270., 2015.
- [10] F. Gers, J. Schmidhuber, F. Cummins, “Learning to Forget: Continual Prediction with LSTM,” In *Proceedings of the 9th International Conference on Artificial Neural Networks, ICANN’99, Edinburgh, UK*, pp. 850–855, 1999.
- [11] P. Valenzuela, J. Gorricho, and de la Iglesia, “Automatic model and feature selection for time series forecasting: Achieving good performance and interpretability,” *Information Sciences*, No.423, pp.157–174, 2018.

- [12] P. Sanguansat, and N. Klomjit, "A comparative study of machine learning techniques for short-term load forecasting," *Energies*, Vol. 12, No.20, 2019.
- [13] G. Fung, and E. Shih, "Evaluating the Forecasting Performance of Facebook's Prophet Model for Time Series Data," *Journal of Open Source Software*, Vol.4, No.43, 2019.
- [14] Tasarruf Bashir, Chen Haoyong, "Short term electricity load forecasting using hybrid prophet-LSTM model optimized by BPNN," *Energy Reports*, Vol 8, Nov. 2022, pp.1678-1686.
- [15] Serdar Arslan, "A hybrid forecasting model using LSTM and Prophet for energy consumption with decomposition of time series data," *PeerJ Computer Science* 8(3), June, 2022.
- [16] Pin Li, Jin-suo Zhang, "A New Hybrid Method for China's Energy Supply Security Forecasting Based on ARIMA and XGBoost," *Energies*, 11(7), June, 2018.
- [17] Yuanhua Chen, Muhammad S.B., Muhammad, A., Dingtian Xiao, "Evaluation of Machine Learning Models for Smart Grid Parameters: Performance Analysis of ARIMA and Bi-LSTM" *Sustainability* 15(11), May 2023.
- [18] G. Peter Zhang, "Time Series Forecasting using a Hybrid ARIMA and LSTM model," Vol. 50, pp. 159-175, 2003.
- [19] Agbessi A.P., Salami A.A., Agbosse K.S., Birregah B. "Peak Electrical Energy Consumption Prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU Approaches," *Energies*, MDPI, 16(12), 4739, June 2023.
- [20] S. J. Taylor and B. Letham, "Prophet: forecasting at scale," *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.1389-1397, 2017
- [21] K. Cho, Van Merriënboer, B., Bahdanau, D., and Y. Bengio, "On the properties of neural machine translation: Encoder-decoder approaches," 2014.

(접수: 2023.07.19. 수정: 2023.08.01. 게재확정: 2023.08.10.)