

초 장단기 통합 태양광 발전량 예측 기법

윤문섭* · 임세령* · 장한승**

Very Short- and Long-Term Prediction Method for Solar Power

Mun Seop Yun* · Se Ryung Lim* · Han Seung Jang**

요 약

세계적 기후 위기와 저탄소 정책 이행으로 신재생 에너지에 관한 관심이 높아지고 이와 관련된 산업이 증가하고 있다. 이 중에서 태양 에너지는 고갈되지 않고 오염 물질이나 온실가스를 배출하지 않는 대표적인 친환경 에너지로 주목받고 있으며, 이에 따라 세계적으로 태양광 발전 시설 보급이 증가하고 있다. 하지만 태양광 발전은 지리, 날씨와 같은 환경의 영향을 받기 쉬우므로 안정적인 운영과 효율적인 관리를 위해 정확한 발전량 예측이 중요하다. 하지만 변동성이 큰 태양광 발전을 수학적 통계 기술로 정확한 발전량을 예측하는 것은 불가능하다. 이를 위해서 정확하고 효과적인 예측을 위해 딥러닝 기반의 기술에 관한 연구는 필수적이다. 또한, 기존의 딥러닝을 활용한 예측 방식은 장, 단기적인 예측을 나누어 수행하기 때문에 각각의 예측 결과를 얻기 위한 시간이 길어진다는 단점이 있다. 따라서, 본 연구에서는 시계열 특성을 가진 태양광 발전량 데이터를 사용하여 장단기 통합 예측을 수행하기 위해 순환 신경망의 다대다 구조를 활용한다. 그리고 이를 다양한 딥러닝 모델들에 적용하여 학습을 수행하고 각 모델의 결과를 비교·분석한다.

ABSTRACT

The global climate crisis and the implementation of low-carbon policies have led to a growing interest in renewable energy and a growing number of related industries. Among them, solar power is attracting attention as a representative eco-friendly energy that does not deplete and does not emit pollutants or greenhouse gases. As a result, the supplement of solar power facility is increasing all over the world. However, solar power is easily affected by the environment such as geography and weather, so accurate solar power forecast is important for stable operation and efficient management. However, it is very hard to predict the exact amount of solar power using statistical methods. In addition, the conventional prediction methods have focused on only short- or long-term prediction, which causes to take long time to obtain various prediction models with different prediction horizons. Therefore, this study utilizes a many-to-many structure of a recurrent neural network (RNN) to integrate short-term and long-term predictions of solar power generation. We compare various RNN-based very short- and long-term prediction methods for solar power in terms of MSE and R^2 values.

키워드

Deep Learning, LSTM, BI-LSTM, Transformer, Ensemble, Solar Power
딥러닝, LSTM, Bi-LSTM, 트랜스포머, 앙상블, 태양광 발전

* 전남대학교 전자통신공학과 (ung5@naver.com, 205749@jnu.ac.kr) · Received : Oct. 06, 2023, Revised : Nov. 08, 2023, Accepted : Dec. 27, 2023

* 저자들은 이 논문에 동등하게 기여했습니다.

· Corresponding Author : Han-Seung Jang

** 교신저자 : 전남대학교 전자통신공학과

Dept. of Electronic Communication Engineering, Chonnam National University

Email : hsjang@jnu.ac.kr

· 접수일 : 2023. 10. 06

· 수정완료일 : 2023. 11. 08

· 게재확정일 : 2023. 12. 27

1. 연구 동향

세계적 기후 위기에 따라 전 세계적으로 탄소 중립 정책을 위해 재생 에너지에 대한 비중을 확대하고 있다. 이러한 재생 에너지 중에서 무한에 가까운 태양 에너지를 이용하는 태양광 발전은 태양광 발전소와 사용 장소의 거리가 가깝고 송전 손실이 낮으며, 보수 및 유지 관리의 수요가 다른 에너지원 시스템에 비해 적은 장점이 있다. 이에 따라 태양광 발전은 가장 대표적인 신재생 에너지로 주목받고 있다[1]. 태양광 발전은 태양의 빛 에너지를 변화시켜 전기를 생산한다. 하지만 태양광 발전 시스템은 자연조건에 따라 전력이 결정되기 때문에 전력 수요가 필요할 시에 전력을 제어할 수 없다는 단점이 있다. 또한, 태양 에너지를 이용하기 때문에 기상 악화에 따른 일사량 감소할 때는 전력 생산과 공급에 한계가 발생하기 때문에 장단기적인 발전량 예측을 통해 기상 상태에 따른 전력 수급 계획을 사전에 수립해야만 한다[2]. 이러한 요구 사항을 충족시키기 위해 정확하고 안정적인 태양광 발전량 예측을 위한 통계적 접근 그리고 인공지능경망 기반의 다양한 연구들이 수행되었다[3-7]. 대표적으로 태양광 발전과 같은 시계열 특성을 가진 데이터는 순환 구조(Recurrent Structure)를 가진 LSTM(Long Short-Term Memory), Bi-LSTM(Bidirectional-LSTM) 등과 같은 딥러닝 모델들이 사용되었으나, 최근에는 자연어 처리, 컴퓨터 비전 그리고 시계열 데이터 예측 분야에서 주목받고 있는 어텐션(Attention), 트랜스포머(Transformer) 등과 같은 최신 메커니즘을 활용하여 기존 인공지능경망 기술보다 높은 예측 성능을 보이는 연구들이 있었다[8-9]. 하지만 앞서 진행되었던 연구들은 장단기적인 태양광 발전 예측 수행에 있어서 장기 혹은 단기에 따른 데이터 구조의 변형 그리고 그에 따른 딥러닝 모델의 하이퍼 파라미터를 찾고 예측을 수행하는 데 있어서 시간의 측면에서 매우 비효율적이다. 따라서 이러한 한계를 극복하기 위해 장단기 예측을 한 번에 수행하는 통합 기법이 필요하다. 따라서, 본 연구에서는 국내 인공지능 대회 플랫폼을 통해서 제공된 데이터를 활용하고 국내 태양광 발전량 데이터에 적합한 예측 딥러닝 모델을 제안한다. 또한, 연구에서는 딥러닝 모델의 입력값과 출력값을 유연하게 조정하는 다대다 방식을 사용하여 단기




그림 1. 입력 변수와 태양광 발전량 간의 상관관계 분석

Fig. 1 The correlation analysis of input variables and solar power

적인 예측뿐만 아니라, 장기적인 예측을 모두 수행할 수 있는 모델 구조를 구축한다. 그리고 이를 다양한 딥러닝 모델에 적용하여 각 모델의 예측 결과를 비교·분석하는 과정을 수행한다.

II. 태양광 발전량 데이터

본 연구에서 사용되는 태양광 발전량 데이터는 국내 인공지능 대회 플랫폼인 Dacon에서 제공받았으며, 특정 지역의 3년간의 태양광 발전량 데이터와 기상 데이터를 활용하고 이를 통해 기계학습 기반의 태양광 발전량 예측을 수행한다.

2.1 데이터 특징 및 다대다 구조

연구에서 사용되는 데이터는 우리나라 특정 지역에서 수집된 3년간의 태양광 발전량 데이터와 기상 데이터를 사용한다. 기상 데이터로 사용되는 데이터의 입력 변수는 날짜(Day), 시간(Hour), 수평 산란 일사량(DHI), 직달 일사량(DNI), 풍속(WS), 상대 습도(RH), 온도(T), 발전량(TARGET)으로 구성되어 있다. 연구에서는 해당 입력 변수와 태양광 발전량과의 관계를 분석하기 위해 상관 분석(Correlation)을 수행하였고, 이는 그림 1을 통해 확인할 수 있다. 여기서 상관 계수 값은 -1과 가까울수록 음의 상관관계, 1과 가까울수록 양의 상관관계를 나타내며, 0의 경우는




그림 2. 발전량과 입력 변수 간의 분포도
Fig. 2 The Distribution of Input variables and solar power

상관관계가 없다는 것을 의미한다. 이를 바탕으로 입력 변수 중 상관관계가 낮은 온도와 풍속을 제외하고 나머지 입력 변수를 사용하여 연구를 수행하였다. 단, 사용되는 입력 변수 중, 시간의 경우에는 상관관계가 낮지만 시간에 따른 발전량 예측을 위해 입력 변수로 활용하였다. 연구에서 사용되는 각 입력 변수에 따른 태양광 발전량의 분포는 그림 2를 통해 확인할 수 있다. 이러한 3년 치의 데이터는 하루 기준 00:00~23:30 동안 30분 단위로 측정되어 하루에 48개의 연속된 시계열의 특성을 가진다. 연구에서 사용되는 태양광 발전량 데이터는 전형적인 시계열 특성을 가진 데이터로서 과거 s 일만큼의 데이터를 사용하여 출력으로 30분~7일 (336개) 후의 발전량을 30분 간격으로 한번에 예측하는 것을 목적으로 한다. 이를 위해 다대다 (Many to Many) 구조를 활용하여 하루에 해당하는 시퀀스 길이는 s 값을 1일(48개), 2일(96개), 3일(144개), 4일(192개), 5일(240개), 6일(288개), 7일(336개)로 변경하며 모델의 성능 평가를 수행한다. 따라서 연구에서 사용되는 기계학습 모델들은 s 값에 따른 총 7개의 예측 모델을 생성하여 학습하게 되고 각 파라미터에 따른 예측 수행 결과를 비교한다. 이를 위해 데이터는 학습(Train), 검증(Validation) 그리고 시험(Test) 데이터로 나누어 구성한다. 학습, 검증, 시험 데이터는 하루를 기준으로 각각 약 80%, 10%, 10%로 나누어 875일, 110일, 110일로 이루어진다.




그림 3. LSTM 모델의 구조
Fig. 3 Structure of a LSTM Model




그림 4. Bi-LSTM 모델의 구조
Fig. 4 Structure of a Bi-LSTM Model

III. 기계학습 모델

3.1 LSTM

LSTM 모델은 RNN(Recurrent Neural Network) 모델이 장기적인 예측을 수행하는 과정에서 이전의 학습에 대한 기억이 줄어들어 학습 능력이 저하되는 단점을 극복하기 위해 제안된 모델이다[10]. RNN 모델과는 달리 LSTM은 단기 기억과 장기 기억을 나누어 학습한 뒤, 두 기억에 대한 학습을 병합하여 예측 확률을 높이는 방식을 사용한다. 본 논문에서는 사용된 LSTM 모델의 구조는 그림 3과 같다. 연구에서 사용하는 LSTM 모델은 2개의 LSTM 층으로 구성되어 있으며 여기서 각 층은 100개의 유닛(units)을 사용한다. 그리고 그림 3에서의 LSTM 모델 구조는 실험을 통해 최적의 결과를 얻은 다대다 구조의 예시를 보여준다. 여기서 모델은 입력층에서 30분 간격의 3일 치 (144개) 사용하여 2층을 이루어진 LSTM 셀을 통해




그림 5. 트랜스포머 모델의 구조
Fig. 5 Structure of a transformer model

학습을 수행한 뒤, 최종적으로 출력층에서 30분 간격의 7일 치(336개)의 발전량을 출력하는 구조를 보여준다.

3.2 Bi-LSTM

Bi-LSTM은 주로 직전의 학습 패턴에 의존하는 LSTM과 RNN 모델의 한계를 극복하기 위해 정보를 역방향과 순방향에서 모두 고려할 수 있는 양방향성은닉 계층을 사용하여 정보를 더욱 유연하게 처리할 수 있는 모델이다[11]. 실험을 통해 최적의 결과를 얻은 Bi-LSTM 모델의 구조는 그림 4와 같으며, 그림에서 모델은 LSTM과 마찬가지로 2층 구조로 되어 있으며 각각 100개의 유닛을 사용한다. 그림4의 Bi-LSTM 모델에서는 입력층에서 30분 간격의 2일 치(96개) 데이터를 사용하여 두 개의 양방향성을 가진 LSTM 셀을 통해 학습이 진행되고, 최종적으로 출력층에서 30분 간격으로 7일 치(336개)의 최적 발전량 예측을 수행하는 다대다 구조를 가진다.

3.3 트랜스포머

트랜스포머 모델은 기존 순환 구조를 가진 신경망 모델에서 발전된 모델로서 입력 시퀀스 내의 모든 값 간의 상호작용을 계산하고 각 특성의 유의성을 학습하는 모델이다. 이러한 특징으로 인해 기존 순환 구조를 가진 모델의 순차적인 처리 방식의 느린 연산 속도와 정보의 병목 현상을 해결할 수 있다. 또한, 장기적인 시계열 데이터를 학습할 시, 발생하는 정보 손실




그림 6. 앙상블 모델의 구조
Fig. 6 Structure of a ensemble model

의 문제와 고질적인 문제인 기울기 소실(Vanishing Gradient) 문제를 해결할 수 있다는 장점이 있다[12]. 연구에서 사용되는 시계열 데이터 예측을 위한 트랜스포머 모델은 1개의 인코더 층을 사용한다.

트랜스포머 모델의 특징은 다른 순환 신경망 모델과 비교했을 때, 데이터를 한 번에 입력하기 때문에 포지셔널 인코딩(Positional Encoding)을 수행하여 입력 순서에 따라 위치 벡터 값을 생성하여 인코더의 입력으로 사용한다. 인코더의 층은 멀티 헤드 어텐션(Multi-Head Attention) 층과 피드 포워드(Feed Forward) 층으로 구성되어 있으며, 각 층은 학습을 위한 잔차 연결을 사용한다. 이때 주어진 입력 시퀀스 데이터의 시간적인 관계성을 추출하는 과정이 수행되고, 인코더는 해당 정보를 벡터의 형태로 변환하여 예측을 수행하게 된다. 그림 5에서 연구를 통해 얻은 최적의 시퀀스를 사용하는 트랜스포머 모델의 구조를 확인할 수 있다. 트랜스포머의 모델은 최적의 결과를 얻기 위해 입력으로 30분 간격의 1일 치(48개) 데이터를 사용하며 1개의 인코더 층을 통해 출력층에서 최종적으로 30분 간격의 7일 치(336개)의 발전량을 출력하는 구조를 보여준다.

3.3 앙상블 기법

앙상블 기법은 다양한 인공지능망 모델에서 출력된 결과를 결합하여 학습에 사용된 여러 모델의 특징과 수행 능력을 최대한 활용하여 예측 성능을 높이기 위해 사용되는 기법이다[13]. 또한, 예측 수행에 있어서 앙상블 기법은 단일 모델을 사용하는 방식보다 성능이 우수하며, 모델의 과적합을 방지할 수 있다는 점과 예측의 안정성이 높아진다는 장점을 가지고 있다.

표 1. 모델별 최적 시퀀스 및 성능 비교
Table 1. The compare the optimal sequence and performance on model

Model	Many to One		Many to Many							
	LSTM		LSTM		Bi-LSTM		Transformer (TF)		Ensemble (LSTM / TF)	
Optimal Seq.	3 or 1		3		2		1		3 / 1	
Metric	MSE	R ²	MSE	R ²	MSE	R ²	MSE	R ²	MSE	R ²
After 30 minutes	18.89	0.9501	32.82	0.9156	26.30	0.9324	20.45	0.9474	22.87	0.9412
After 1 hour	21.72	0.9426	35.53	0.9087	32.26	0.917	28.09	0.9278	28.94	0.9256
After 12 hours	67.60	0.8214	69.03	0.8219	72.43	0.8132	68.40	0.8236	66.73	0.8279
After 1 day	80.37	0.7877	70.77	0.8171	73.82	0.8092	75.11	0.8058	71.33	0.8156
After 3 days	72.93	0.8073	74.27	0.8026	75.80	0.7986	76.33	0.7972	73.65	0.8043
After 5 days	92.41	0.7559	81.19	0.7796	82.08	0.7772	81.03	0.7800	79.20	0.7850
After 7 days	83.27	0.7800	79.75	0.7733	77.15	0.7807	75.97	0.7840	76.17	0.7835
Average (After 30 minutes ~ 7 days)	-	-	74.95	0.7992	77.82	0.7916	78.53	0.7897	74.77	0.7997

따라서 논문에서는 그림 6과 같이 LSTM 그리고 트랜스포머 모델에서 수행된 예측 결과를 반영하기 위해 앙상블 기법을 사용하여 두 모델의 성능을 결합하여 최종적인 예측을 수행한다.

IV. 실험 결과

본 연구에서는 Python과 오픈소스 기반 딥러닝 프레임워크인 TensorFlow를 활용하였다. 데이터의 개수를 N 개라고 했을 때, 입력 데이터는 시퀀스 길이(s)에 따라 $[N \times s \times 48]$ 의 크기를 갖게 되며, 출력 데이터의 크기는 7일(30분~7일)의 길이에 따라 $[N \times 7 \times 48]$ 의 크기를 갖게 된다. 효율적인 학습을 위해 데이터는 정규화(Min Max Scaler) 과정을 거쳐 전처리된다. 이러한 과정을 거친 입력 데이터를 학습한 기계 학습 모델은 출력 데이터 크기에 따른 예측 결과를 출력하게 된다. 학습 데이터로 학습을 수행한 후, 최적의 파라미터를 찾기 위해 검증 데이터를 활용하였다. 이때 학습의 비용 함수는 수식(1)의 MSE(Mean Square Error)를 사용한다. 성능의 검증 척도로서 MSE와 수식(2)의 결정계수(R^2)를 활용한다. 이후 시험 데이터를 사용하여 최적의 파라미터로 이루어진 모델의 최종적인 성능을 평가한다.

$$MSE = \sqrt{\sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad \dots (1)$$

$$R^2 = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad \dots (2)$$

시험 데이터를 활용하여 최적의 파라미터를 적용한 각 모델로 태양광 발전량을 예측한 결과는 대표적으로 초단기 주기인 30분 후에 대해 그림 7을 통해 나타내었다. 이를 통해 각 모델의 예측값이 발전량의 실제 추세를 비슷하게 따라가는 것을 알 수 있다. 표 1에서는 논문에서 제안하는 다대다 모델별 최적의 시퀀스(s)와 성능을 확인할 수 있다. 성능은 MSE와 결정계수로 나타내었으며 예측 주기에 따라 계산한다. 대표적으로 30분, 1시간, 12시간, 1일, 3일, 5일, 7일 후의 단기(short) 및 장기(long) 예측 성능을 비교하였다. 이때 다수의 예측 주기가 아닌 하나의 주기만을 예측하는 것을 목표로 하는 다대일(Many to One) 구




그림 7. 태양광 발전량 예측 결과
Fig. 7 The result of solar power prediction

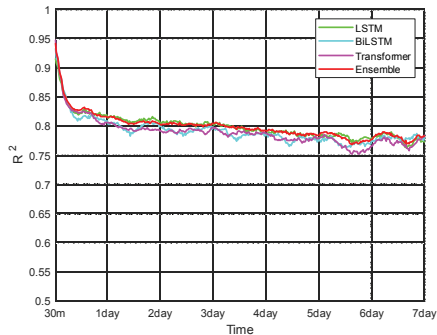


그림 8. 모델별 결정계수
Fig. 8 The coefficient of determination on model

조를 가지는 장기 혹은 단기 예측 모델의 성능을 제시하였다. 이러한 모델은 표 1에 나타낸 7개의 예측 주기를 하나씩 예측할 수 있기에, 예측 주기마다 각각의 모델을 생성해야 한다는 단점이 있지만 각 예측 주기에 최적의 성능을 보인다는 장점이 있다. 하지만 이와 같은 특징을 가지는 다대일 구조의 성능과 제안하는 다대다 구조의 장단기 통합 예측 모델의 성능이 유사함을 확인할 수 있다. 이는 각 예측 주기의 최적의 성능을 제안하는 다대다 구조에서도 제공함을 의미한다. 또한, 다대다 구조에서 장단기의 대표적인 성능은 트랜스포머 모델과 앙상블 모델이 가장 높다. 통합 7일 (30분~7일) 성능의 평균값에서는 앙상블 기법을 사용한 모델이 가장 성능이 우수한 것을 확인할 수 있다. 연구에서는 모든 주기의 예측 성능을 확인하기 위해 결정계수의 값을 그림 8을 통해 나타내었다.

30분~12시간 후는 예측 주기가 커짐에 따라 결정계수의 값이 약 10% 정도 떨어지고, 이후의 예측 주기에서는 약 0.75~0.8 사이의 범위에서 결정계수의 값을 가진다.

V. 결 론

본 연구에서는 다대다 구조를 활용한 딥러닝 기반의 장단기 통합 태양광 발전량 예측을 수행하였다. 제안된 방식은 입력 데이터의 길이를 1일부터 7일까지 변경하며 학습하여, 30분부터 7일 후까지를 30분 단위로 한꺼번에 예측할 수 있는 모델의 최적 시퀀스 파라미터를 찾았다. 기존 예측 방식에서 하나의 주기를 예측하는 모델은 다양한 주기를 예측하기 위해서는 주기별로 다수의 모델을 생성하고 추가적인 학습이 수행되어야 하는 한계가 있다. 하지만 본 연구에서 제안하는 초 장단기 태양광 발전량 예측 방식은 하나의 예측 모델로 다양한 예측 주기를 동시에 예측하는 것이 가능하다. 본 연구에서는 제안하는 기법의 성능 평가를 위해 수치적인 검증 척도를 통해서 하나의 단기 혹은 장기 주기를 예측하는 방식과 제안하는 통합 방식의 성능이 유사함을 확인할 수 있었다. 따라서 본 논문에서 제안하는 방식을 통해 정확한 태양광 발전량 예측값을 활용하여 안정적인 전력 수급을 확보할 수 있다는 점과 다양한 주기의 관점에서 수행된 장단기 통합 예측값을 확인할 수 있다는 장점을 통해, 소규모 그리드에서 다양한 장단기적인 시점에서 에너지 스케줄링을 정확하게 조정하여 에너지 저장 장치의 사용을 최소한으로 줄임으로써 경제적 에너지 사용 효과를 얻을 수 있을 것으로 예상된다.

감사의 글

본 논문은 전남대학교 학술연구비(과제번호: 2021-2176) 지원에 의하여 연구되었음.

References

- [1] H. Kim, G. Yang, C. Nam, S. Jeong and S. P. Jung, "Solar photovoltaic industry in Korea: current status and perspectives," *J. of Korean Societ*

- y of *Environmental Engineers*, vol. 45, no. 2, Feb. 2023, pp. 107-119.
- [2] M. Kim, S. Jung, J. Kim, H. Lee, B. Kim and S. Kim, "A Study on Artificial Neural Network-based Solar Radiation Forecasting for Efficient Solar Photovoltaic System," *J. of Korean Institute of Intelligent Systems*, vol. 29, no. 6, Dec. 2019, pp. 501-506.
- [3] S.-M. Lee, J.-A. Noh, S.-J. Kang and J.-W. Park, "A Study on Machine Learning Models and Trends for Forecasting of Photovoltaic Power Generation," *Conf. The Korean Institute of Electrical Engineers*, Oct. 2021, pp. 169-170.
- [4] S.-R. Jung, J. Koh and S.-K. Lee, "Recurrent Network based Prediction System of Agricultural Photovoltaic Power Generation," *J. of the Korea institute of Electronic Communication*, vol. 17, no. 5, 2022, pp. 825-832.
- [5] M. A. Bou-Rabee, M. Y. Naz, I. E. Albalaa and S. A. Sulaiman, "BiLSTM Network-Based Approach for Solar Irradiance Forecasting in Continental Climate Zones," *Energies*, vol. 15, no. 6, 2022, 2226.
- [6] S.-R. Jung, K.-W. Park and S.-K. Lee, "Intelligent Prediction System for Diagnosis of Agricultural Photovoltaic Power Generation," *J. of the Korea institute of Electronic Communication*, vol. 16, no. 5, 2021, pp. 859-866.
- [7] M.-Y. Kang, "Renewable Energy Generation Prediction Model using Meteorological Big Data," *J. of the Korea institute of Electronic Communication*, vol. 18, no. 1, 2023, pp. 39-44.
- [8] Y. Zhou, Y. Li, D. wang, and Y. Liu "A multi-step ahead global solar radiation prediction method using an attention-based transformer model with an interpretable mechanism," *Int. J. of Hydrogen Energy*, vol. 48, no. 40, May, 2023, p. 15317-15330.
- [9] A. Heidari and D. Khovalyg, "Short-term energy use prediction of solar-assisted water heating system: Application case of combined attention-based LSTM and time-series decomposition," *Solar Energy* vol. 207, no 1, Sept., 2020, pp. 626-639.
- [10] A. Graves, "Long short-term memory," *Supervised sequence labelling with recurrent neural networks*, Berlin : Springer, 2012, pp. 37-45.
- [11] T. Peng, C. Zhang, J. Zhou and M. S. Nazir, "An integrated framework of Bi-directional long-short term memory (BiLSTM) based on sine cosine algorithm for hourly solar radiation forecasting," *Energy* vol. 221, Apr., 2021. pp. 119887.
- [12] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez and I. Polosukhin, "Attention is all you need," *Advances in neural information processing systems* 30, 2017.
- [13] N. Rahimi, S. Park, W. Choi, B. Oh, S. Kim, Y. Cho and D. Lee, "A Comprehensive Review on Ensemble Solar Power Forecasting Algorithms," *J. of Electrical Engineering & Technology*, Jan., 2023, pp. 719-733.

저자 소개

윤문섭(Mun-Seop Yun)



2021년 전남대학교 전자통신공학과 졸업(공학사)

2023년 전남대학교 대학원 전자통신공학과 졸업(공학석사)

※ 관심분야 : IoT, 셀룰러 임의접속, 딥러닝

임세령(Se-Ryung Lim)



2020년~현재 전남대학교 전자통신공학과 재학(학사)

※ 관심분야 : 셀룰러 임의접속, 딥러닝, 에너지 ICT

장한승(Han-Seung Jang)



2012년 전남대학교 전자컴퓨터공학부 졸업(공학사)

2014년 한국과학기술원 전기전자공학부(공학석사)

2017년 한국과학기술원 전기전자공학부(공학박사)

2019년~현재 전남대학교 전자통신공학과 부교수

※ 관심분야 : IoT, 기계학습, 에너지 ICT

