

미래 기상정보를 사용하지 않는 LSTM 기반의 피크시간 태양광 발전량 예측 기법

A LSTM Based Method for Photovoltaic Power Prediction in Peak Times Without Future Meteorological Information

이동훈(Donghun Lee)*, 김관호(Kwanho Kim)**

초 록

최근 태양광 발전량 예측은 태양광 발전량 설비 시스템의 안정적인 작동을 위한 조정 계획, 설비 규격 결정 및 생산 계획 일정을 수립하기 위해 필수적인 요소로 고려된다. 특히, 대부분의 태양광 발전량은 피크시간에 측정되기 때문에, 태양광 시스템 운영자의 이익 최대화와 전력 계통량 안정화를 위해 피크시간의 태양광 발전량 예측은 매우 중요한 요소이다. 또한, 기존 연구들은 광범위한 지역에서 예측된 불확실한 기후 정보들을 이용하여 태양광 발전량을 예측하는 한계점 때문에 일사량, 운량, 온도 등과 기상정보 없이 피크시간의 태양광 발전량을 예측하는 것은 매우 어려운 문제로 고려된다. 따라서 본 논문에서는 피크이전의 기후, 계절 및 관측된 태양광 발전량을 이용하여 미래의 기후 및 계절 정보 없이 피크시간의 태양광 발전량을 예측할 수 있는 LSTM(Long-Shot Term Memory) 기반의 태양광 발전량 예측 기법을 제안한다. 본 연구에서 제안한 모델을 기반으로 실 데이터를 통한 실험 결과, 단기 및 장기적 관점에서 높은 성능을 보였으며, 이는 본 연구에서 목표로 한 피크시간의 태양광 발전량 예측 성능 향상에 긍정적인 영향을 나타내었음을 보여준다.

ABSTRACT

Recently, the importance prediction of photovoltaic power (PV) is considered as an essential function for scheduling adjustments, deciding on storage size, and overall planning for stable operation of PV facility systems. In particular, since most of PV power is generated in peak time, PV power prediction in a peak time is required for the PV system operators that enable to maximize revenue and sustainable electricity quantity. Moreover, Prediction of the PV power output in peak time without meteorological information such as solar radiation, cloudiness, the temperature is considered a challenging problem because it has limitations that the PV power was predicted by using predicted uncertain meteorological

* 이 논문은 2017년도 정부(미래창조과학부) 한국연구재단이 후원하는 개인기초연구사업(No.NRF-2017R1D1A1B03035639) 지원을 받아 수행된 연구임.

** First Author, Department of Industrial and Management Engineering, Incheon National University (dhlee@inu.ac.kr)

*** Corresponding Author, Dept. of Industrial and Management Engineering, Incheon National University (khokim@inu.ac.kr)

Received: 2019-10-29, Review completed: 2019-11-21, Accepted: 2019-11-26

information in a wide range of areas in previous studies. Therefore, this paper proposes the LSTM (Long-Short Term Memory) based the PV power prediction model only using the meteorological, seasonal, and the before the obtained PV power before peak time. In this paper, the experiment results based on the proposed model using the real-world data shows the superior performance, which showed a positive impact on improving the PV power in a peak time forecast performance targeted in this study.

키워드 : 태양광 발전량 예측, 딥러닝, 시계열 분석, 장기-단기 기억 메모리

Photovoltaic Power Prediction, Deep Learning, Time Series Analysis, Long-short Term Memory

1. 서 론

태양광 발전량(Photovoltaic Power) 예측은 태양광 발전량 설비 시스템의 안정적인 작동을 위한 조정 계획, 설비 규격 결정 및 효율적인 생산 계획 일정을 수립하기 위해 필수적인 요소이다[1]. 대규모 태양광 발전소에서 생산된 태양광 발전량의 양은 기상 조건 및 시스템 작동 능력과 저장 용량 크기를 결정하는 능력에 따라 크게 달라진다. 이러한 이유로 인해 발전소 운영자는 발전소의 전반적인 운영 계획을 결정하기 어려울 수 있다. 운영자들은 태양광 발전량 예측 시스템을 활용함으로써 저장 용량 크기 조정과 세분화된 운영 계획을 결정을 가능하게 한다.

또한 운영자의 이익을 최대화하기 위해 피크 시간의 태양광 발전량을 예측하는 것은 매우 중요하다. 태양광 발전량으로 생성된 전력의 가격은 전기의 소모량이 가장 많고 많은 양의 태양광 발전량이 측정되는 피크시간 때에 전력의 가격이 상승한다. 운영자의 이익은 피크시간의 태양광 발전량이 얼마나 많이 측정될지 예측하는 능력에 따라 달라진다. 하루 중 시간에 따라 태양광 발전량의 가격이 입찰되는 시

장이 증가함에 따라 피크시간의 태양광 발전량 예측은 더욱더 필요한 요소로 고려되어지고 있다[31].

게다가 역동적으로 변화하는 국내 기후 특성으로 인해 피크시간의 태양광 발전량 예측은 미리 전력 계통량 확보와 합리적인 전력 생산 계획을 통해 대규모 공장 및 가정의 전력사용 안정화에 도움을 줄 수 있다. 국, 내외적으로 전력 계통량 안정화를 위해 마이크로그리드 시스템과 DR(Demand Response)에 관한 많은 연구가 진행되고 있다[4, 5, 23]. 이와 같은 시스템은 태양광 발전량과 같은 분산 자원들을 활용하여 전력 계통량 확보뿐만 아니라 연료비, 전기요금 등 운영비용을 감소하는데 장점이 있다. 특히, 분산 자원 중 하나인 태양광 발전량은 전력 사용량이 증가하는 피크시간에 전력 계통량의 급격한 변화의 대응하여 시스템 운영과 경제성 확보에 도움을 줄 수 있다.

그러나 일사량, 운량, 온도 등과 같은 기상정보 없이 피크시간의 태양광 발전량을 예측하는 것은 어려운 문제이다. 태양광 발전량은 일사량, 온도와 같은 다양한 기상 요인들로부터 영향을 받는 것으로 알려져 있다[28]. 이러한 기후 정보들은 특정 지역에 따라 알 수 없고 광범위

한 지역에 대한 정보만을 알 수 있는 한계점이 존재한다. 또한, 기후정보들은 시간 및 지역 기후조건에 따라 역동적으로 변화하기 때문에 기후정보를 예측하는 것은 한계점이 존재한다[20]. 따라서 피크시간의 태양광 발전량과 피크 시간 이전의 태양광 발전량의 차이가 특정 날과 계절에 따라 달라져 피크시간의 태양광 발전량 예측을 더욱 어렵게 한다.

이러한 어려움에도 불구하고, 대부분의 연구들은 통계 및 인공 신경망 기반 모델을 기반으로 예측된 미래의 기상정보와 일사량을 이용하여 태양광 발전량을 예측하는 문제를 중점적으로 다루었다[2, 15-17, 20, 25, 26]. 그러나 이러한 연구들은 태양광 발전량 예측을 위해서는 미래의 기후정보들이 반드시 준비되어 있어야 한다는 한계점이 존재한다. 또한, 특정 지역에 따라 기후 정보를 예측할 수 없음에도 불구하고 예측된 미래의 기후정보를 사용한다는 한계점이 존재한다.

따라서 본 논문에서는 미래의 기후정보를 사용하지 않고 피크시간에서의 태양광 발전량 예측을 위한 LSTM(Long-Short Term Memory) 기반의 모델을 제안한다. 제안된 모델은 피크 시간 이전에 관측된 태양광 발전량과 기후정보만을 이용하여 피크시간 동안 태양광 발전량을 예측한다. 즉, 피크시간은 하루 중 태양광 발전량이 가장 많이 측정되는 시간이기 때문에 본 연구에서 제안한 모델을 이용하여 태양광 발전소 운영 계획과 이익을 최대화하는데 도움을 줄 수 있다.

구체적으로 본 연구에서 제안한 LSTM 기반의 태양광 발전량 예측 모델은 장기적 관점에서 계절의 따른 태양광 발전량 변화의 경향성 뿐만 아니라 단기적 관점에서 하루 동안의 태

양광 발전량 간의 복잡한 시계열 패턴을 모두 이해할 수 있도록 설계되었다. 실제 데이터를 이용한 본 연구에서 제안한 실험 결과, LSTM 기반의 태양광 발전량 예측 모델은 전체적으로 우수한 성능을 보였으며, 특히 예측하기 어려운 피크이전의 태양광 발전량과 피크시간의 태양광 발전량과의 차이가 많을 때에도 높은 성능을 보였다.

본 논문의 구성은 다음과 같다. 제2장에서 관련 연구에 대해 설명하고, 제3장에서는 문제정의와 제안한 모델에 대한 내용을 설명한다. 제4장에서는 제안한 LSTM 기반의 태양광 발전량 예측 모델에 대한 성능을 평가하고 마지막으로 제5장에서 결론을 기술한다.

2. 관련 연구

기존 연구는 태양광 발전량 예측을 위한 접근 방법 측면에서 <Table 1>과 같이 연구되었다. 첫 번째, 하이브리드 및 시계열 분석 모델과 같은 통계적 방법을 기반으로 개발되어진 모델들은 기후 및 기상정보를 이용하여 태양광 발전량을 예측하였다[3, 6, 18, 19]. 구체적으로 재생 에너지원 하나 이상을 통합한 하이브리드 모델을 이용하여 기후 정보를 이용하여 태양광 발전량을 예측하였고[6, 18], 시계열을 통계적 기법 중 하나인 ARIMA 모델을 이용하여 태양광 발전량을 예측하였다[19].

두 번째, 머신러닝 기법 중 SVM과 KNN 기반으로 기후정보를 이용하여 태양광 발전량을 예측하였다[8, 29]. 또한, 태양광 발전량 예측 모델은 기후 정보를 예측 및 분류를 통하여 개발되었다[9, 27].

〈Table 1〉 Overview of Previous Research Related to PV Power Prediction

Approaches	Used Features	References
Statistical Methods	Clear Sky Model and Normalized PV Power Generation	Bacher et al.[3]
	Meteorological Information	Li, Su, and Shu[19], Chattopadhyay et al.[6], Jurasz and Ciapala [18]
Machine Learning	Meteorological Information	Zeng and Qiao[29], De Giorgi et al.[8]
	Numerical Weather Predictions	Da Silva Fonseca et al.[9]
	Weather Classification	Shi et al.[27]
Deep Learning	Meteorological Information	Izgi et al.[16], Lee and Kim[22], Sulaiman et al.[25], Jiahao et al.[17]
	Clearness Index	Ashraf, I., and Chandra, A.[2]

마지막으로 딥러닝 기반의 태양광 발전량을 예측하는 연구가 활발하게 진행되었다[2, 16, 17, 20, 25]. 먼저, 태양광 발전량을 예측하기 위해 은닉층의 개수가 하나인 ANN 기반의 태양광 발전량 예측 모델을 제안하였다[16, 25]. 나아가 여러 개의 은닉층을 이용하는 DNN기반의 태양광 발전량 예측 모델은 태양광 발전량 예측을 향상시키기 위해 제안되었고[16, 20], 또 다른 DNN 기반의 태양광 발전량 예측 모델은 맑은 날을 초점으로 태양광 발전량을 예측하기 위해 개발되었다[1]. 하지만 기존 연구들에서는 기후정보를 이용하여 시계열 분석 기법과 인공신경망 모델을 활용하여 태양광 발전량을 예측하는데 초점을 두고 있다. 따라서 본 연구에서는 특정지역에 기후정보를 예측하는 한계점을 해결하기 위해 피크시간 이전의 기후, 계절, 측정된 태양광 발전량 정보만을 이용하여 미래의 기후 및 계절 정보를 사용하지 않고 태양광 발전량을 예측할 수 있는 LSTM 기반의 피크시간 태양광 발전량 예측 기법을 제안한다.

3. 제안 기법

3.1 문제 정의

본 연구에서 다루고 있는 목표는 과거 연구와는 다르게, 피크시간의 태양광 발전량을 예측할 때 피크시간의 예측된 기후 및 계절 정보 없이 피크시간 이전의 측정된 기후 정보, 계절 정보, 그리고 태양광 발전량만을 이용하여 예측하는 것이다.

〈Table 2〉는 피크시간의 태양광 발전량 예측을 위해 본 연구에서 고려하고 있는 변수들을 나타낸다. 먼저 제안한 모델의 학습에 사용되는 입력 값은 기후정보, 계절 정보, 피크시간 이전의 태양광 발전량 정보가 있다. 기후정보로는 온도(e), 습도(k), 운량(c), 일사량(r)을 고려하고, 계절 정보는 월정보(a), 일정보(b), 마지막으로 피크시간 바로 이전의 태양광 발전량(y')을 고려한다. 출력 값으로는 예측된 태양광 발전량($\hat{y}$)이 있다.

따라서 입력 값 $\langle e_i, k_i, c_i, r_i, a_i, b_i, y'_i \rangle$ 는

〈Table 2〉 Inputs and Outputs at Peak Times($i=1,...,n$, Using The Previous Data at Peak Times and $j=1,...,m$, Using The Data at Peak Times)

	Categories	Features	Notations
Inputs	Meteorological and Seasonal Information	Temperature (e)	e_i
		Humidity (k)	k_i
		Cloudiness (c)	c_i
		Radiation (r)	r_i
		Month of year (a)	a_i
		Day of month (b)	b_i
	Previous PV Power Output in a Peak Time	PV power (y')	y'_i
Output	PV Power Output in a Peak Time	Predicted PV power ($\hat{y}$)	$\hat{y}_j$


하루 중 i 번째 피크시간 바로 이전의 정보로 이루어진 벡터를 이용하여 학습하고, 피크시간의 태양광 발전량(y)을 잘 예측하려고 시도한다.

3.2 제안한 모델의 프레임워크

〈Figure 1〉은 피크시간 이전의 측정된 기후

정보, 계절 정보, 태양광 발전량 정보를 이용하여 LSTM 기반의 모델 학습 방법을 통한 태양광 발전량을 예측하기 위한 제안된 프레임워크를 나타낸다. 구체적으로 본 연구에서 제안한 프레임워크는 학습 과정과 테스트 과정으로 구성된다.

학습 과정에서는 노이즈를 포함하는 과거의 관측된 피크시간 이전의 기후, 계절, 태양광 발



〈Figure 1〉 The Proposed Framework for The PV Power Prediction in Peak Times

전량 데이터를 이용하여 피크시간의 태양광 발전량을 예측하기 위한 숨겨진 패턴을 찾기 위해 학습한다. 특히, 피크시간은 피크이전의 시간보다 길기 때문에 입력 값으로 사용되는 시계열 정보보다 출력 값의 시계열 정보가 더 길어 예측하기 어려움이 존재한다. 그러나 본 연구에서 제안한 프레임워크는 피크시간 이전의 정보들과 피크시간의 태양광 발전량과의 관계성 이해함으로써 학습할 수 있도록 설계되었다. 즉, 예측하려는 태양광 발전량의 시간 범위가 입력 값으로 사용되는 시간 범위와의 차이가 있음에도 불구하고 태양광 발전량 예측 성능을 향상시킬 수 있는 장점을 가진다.

테스트 과정에서는 학습과정에서 사용하지 않는 데이터를 이용하여 모델의 성능을 평가한다. 따라서 모델의 성능은 실제 환경에서 생성된 데이터로 간주하여 테스트함으로써 실제 환경에 적용하여 태양광 발전량을 예측할 수 있다는 장점을 가진다.

3.3 LSTM 기반의 태양광 예측 모델


LSTM 기반의 피크시간 태양광 예측 모델은 피크이전의 태양광 발전량과 피크시간의 태양광 발전량과의 순차적 패턴을 정확하게 학습하기 위해 개발된 분석 기법이다. LSTM 기반의 모델은 언어 번역, 컴퓨터 비전과 같은 시퀀스 데이터의 복잡한 문제를 해결하기 위해 많이 적용되어졌다[7, 10, 12, 24].

본 연구에서 제안한 LSTM 기반의 모델은 입력 값, 활성화함수, 손실함수 및 최적화 기법을 기반으로 학습한다. LSTM 기반의 모델은 기존의 신경망 모델과는 달리 은닉층의 가중치 값을 서로 공유하기 때문에 순환층(Recurrent

Layer)으로 구성 되어있다. 따라서, 본 연구에서 제안한 LSTM 기반의 피크시간 태양광 예측 모델은 학습 과정에서 사용되는 입력 값 $x_i, i = 1, \dots, n$,는 각각의 입력층, 순환층, 출력층에 있는 연결 가중치와 활성화 함수와의 계산을 통해 비선형 값으로 변환된다. 본 연구에서는 시간을 통한 역전파(Backpropagation Through Time Method) 기법을 적용하여 제안한 모델이 단기적 및 장기적 관점에서 숨겨진 시계열 패턴들의 파라미터들과 예측된 태양광 발전량과 실제 태양광 발전량의 오차를 최소화하기 위한 연결 가중치를 찾기 위해 반복적으로 학습한다[11].

<Figure 2>는 피크시간의 태양광 발전량을 예측하기 위해 제안된 모델의 네트워크 구조를 보여준다. 제안한 모델은 피크시간의 정확한 태양광 발전량을 예측하기 위해 단기 및 장기적 관점에서의 정보를 제어하는 셀을 가지고 있다. 따라서 순환층에 있는 셀들은 본 연구에서 제안한 모델이 학습하는 동안 피크시간 이전의 정보들과 피크시간 동안 태양광 발전량과의 숨겨진 시계열 관계성을 잘 이해할 수 있도록 하는 역할을 담당한다.

<Figure 2>와 같이, LSTM 모델에 있는 셀은 망각 게이트(Forget Gate), 입력 게이트(Input Gate), 출력 게이트(Output Gate)로 구성되어 있다. 망각 게이트는 과거의 정보를 얼마만큼 기억할지를 정하고, 입력 게이트는 현재의 정보를 얼마만큼 기억할지를 정한다. 마지막으로 출력 게이트는 망각 게이트와 출력게이트를 통해 계산된 값을 기반으로 단기 및 장기적 정보를 제어하여 출력한다. 따라서 각각의 게이트들은 식 (1-6)을 통해 정보들을 제어한다.



〈Figure 2〉 Network Structure of The Proposed LSTM Based PV Power Prediction Model

$$f_i = \sigma(W_{x_i} x_i + W_{h_f} h_{i-1} + b_f) \quad (1)$$

$$u_i = \sigma(W_{x_{iu}} x_i + W_{h_u} h_{i-1} + b_u) \quad (2)$$

$$o_i = \sigma(W_{x_{io}} x_i + W_{h_o} h_{i-1} + b_o) \quad (3)$$

$$g_i = \tanh(W_{x_{ig}} x_i + W_{h_g} h_{i-1} + b_g) \quad (4)$$

$$z_i = (f_i \otimes z_{i-1}) + (g_i \otimes u_i) \quad (5)$$

$$h_i = o_i \otimes \tanh(z_i) \quad (6)$$

여기에서 f_i, u_i, o_i 는 각각 망각 게이트, 입력 게이트, 출력 게이트를 나타내며, g_i, z_i, h_i 는 후보 장기 메모리, 장기 메모리, 단기 메모리를 나타낸다. 연결 가중치 $W_{h_f}, W_{h_u}, W_{h_o}$ 와 바이어스 가중치(Bias Weight) b_f, b_u, b_o 는 같은 크기의 벡터 사이즈를 갖는다. 여기에서 $\otimes$ 는 요소별 곱셈을 나타내고 $\tanh(\cdot)$ 함수는 하이퍼


볼릭 탄젠트 함수를 나타낸다. 또한, 모든 게이트에는 시그모이드 함수 $\sigma(\cdot)$ 를 적용하였다.

따라서, 망각 게이트 f_i 는 x_i 를 입력으로 받아 $i-1$ 번째의 피크시간의 태양광 발전량과 피크시간 바로 이전의 정보들 간의 숨겨진 패턴을 저장하고 있는 h_{i-1} 와의 계산을 통해 $i-1$ 번째의 숨겨진 패턴의 정보 기억 유무를 결정한다. 입력 게이트 u_i 는 h_{i-1} 와의 계산을 통해 i 번째의 피크시간의 태양광 발전량과 피크시간 바로 이전의 정보들 간의 관계 정보의 양을 결정한다. 또한, 후보 장기 메모리 g_i 와 계산을 통해 계절변화에 따른 관계 정보를 저장하고 있는 장기 메모리 z_i 의 저장할 양을 결정한다. 마지막으로 출력 게이트 o_i 는 계산된 z_i 와 탄젠트 함수를 통해 최종적으로 i 번째의 피크시간의 태양광 발전량

과 피크시간 바로 이전의 정보들 간의 관계 정보를 가지고 있는 단기 메모리 h_t 의 저장의 양을 결정하고 출력한다. 세 개의 게이트를 통해 학습 과정에서 단기적과 장기적 관점에서 저장된 기억 메모리를 컨트롤하여 피크시간의 태양광발전량과 바로 이전의 정보들 간의 숨겨진 시계열 패턴을 찾기 위해 시도한다.

3.4 모델 학습 과정

<Figure 3>은 학습 및 검증 데이터를 이용하여 본 연구에서 제안한 LSTM 기반의 태양광 발전량 예측 모델의 학습과정 결과를 나타낸다. 제안된 모델은 학습에 사용되는 입력 값의 시계열 정보를 고려하여 배치사이즈를 1로 설정하였다. 또한 제안한 모델의 학습 반복 횟수는 100으로 설정하였고 조기종료 설정을 20으로 설정하였다.



<Figure 3> Changes of Train and Validation Loss Values According to Epochs

학습 반복 횟수가 많으면 많은 과적합(Overfitting)으로 인해 모델의 성능이 저하될

수도 있고, 학습 반복 횟수가 적으면 소적합(Underfitting)으로 인해 모델의 성능이 저하가 발생하여 성능이 저하될 수 있기 때문에, 조기 종료 설정을 통해 검증 데이터가 25번의 반복적인 학습동안 학습의 개선이 없을 경우 학습이 자동적으로 종료된다.

또한 제안한 모델의 성능을 향상시키기 위해, 본 연구에서는 이전 연구들에서 성공적으로 적용된 파라미터들을 참고하여 드롭아웃(Dropout)과 batch size는 0.3과 0.001으로 각각 적용하였고, 초기 가중치를 적절한 값으로 설정하는 것이 중요하지만 초기 값을 0에서 1로 랜덤하게 설정하였다[12]. 마지막으로 입력 및 출력 값은 단위를 일치시키기 위해 Min-Max 정규화를 사용하여 0에서 1사이로 범위로 변환하였다[30].

학습 파라미터를 최적화하기 위해 사용되는 활성화 함수와 최적화 기법은 Rectified Linear Unit(ReLU)와 Adagrad를 각각 사용하였다. 또한 순환층 개수는 2개로 설정하였다. 활성화 함수, 최적화 기법, 순환층 개수에 따라 모델의 성능은 차이가 발생하지만, 본 연구에서는 반복적인 실험을 통해 학습 파라미터들을 설정하였다.

4. 실험 및 평가

4.1 실험 데이터 설정

본 연구에서 제안한 LSTM 기반의 피크시간 태양광 발전량 예측 모델을 학습하기 위해 사용한 기상정보 데이터는 한국 기상청에서 제공하는 데이터를 수집하였고 태양광 발전량은 구

〈Table 3〉 Used Input and Output Values for Learning and Testing The Proposed Model (August 9, 2015)

	Input values				Output values				
Hours	06	07	08	09	10	11	12	13	14
Temperature (°C)	24	24.4	25.6	27.3					
Humidity (%)	90	88	84	76					
Cloudiness index	3	3	2	2					
Radiation (W/m ²)	0	32.3	104.4	208.3					
Month of year (-)	8	8	8	8					
Day of month (-)	9	9	9	9					
The PV power output before a peak zone (Kw)	0	1	1	4					
The PV power output in a peak zone (Kw)					10	17	20	21	20

미에 있는 과학기술연구지원 센터에 설치되어 있는 태양광 모듈에서 측정된 실제 태양광 발전량 데이터를 수집하였다.

〈Table 3〉은 제안한 모델을 학습 및 평가를 위해 사용된 데이터의 입력 및 출력 예시를 나타낸다. 제안한 모델을 학습하기 위한 데이터는 2013년 1월부터 2015년 6월까지의 데이터 8,199개를 사용하였고 학습 시 유효성을 검증하기 위한 데이터는 2015년 7월부터 2015년 12월까지의 데이터 1,656개를 사용하였다. 모델의 성능을 검증하기 위한 테스트 데이터는 2016년 3월, 4월, 8월, 10월의 데이터 1,107개를 사용하였다.

4.2 실험 설정

본 연구에서 사용된 계절 정보는 월의 정보와 일의 정보가 있다. 월의 정보는 각 월의 값을 나타내고 일의 정보는 각 일의 값을 나타낸다. 만약 9월 8일인 경우 월의 값은 9이고 일의 값은 8일이 된다. 습도의 범위는 0에서 100이며 높을수록 습도가 높다는 것을 나타낸다. 운량의 범


위는 0에서 10이며 높을수록 운량이 많아 날씨가 흐리다는 것을 나타낸다. 피크시간은 국가와 지역적 특성에 따라 다양한 시간으로 정의되지만[28,29] 본 연구에서는 수집한 데이터를 기반으로 피크이전의 시간을 06:00~09:00, 피크시간을 10:00~14:00로 설정하였다. 따라서, 입력 값 n 은 4로 설정하였고, 출력 값 m 은 5로 설정하였다.

기존 연구와는 달리 본 연구에서 제안한 모델은 미래의 기후 정보를 예측하지 않고 과거의 관측된 정보만을 이용하여 미래의 태양광 발전량을 예측하기 때문에 본 연구에서 제안한 모델을 기반으로 실험 데이터를 이용한 전반적인 성능 평가와 계절에 따른 성능 평가를 실시한다. 본 연구에서 제안하는 예측 모델들이 얼마나 실제 태양광 발전량을 잘 추정하는지 정량화하기 위해 주어진 입력 값에 대한 예측된 태양광 발전량과 실제 발전량과의 차이를 평균 제곱 오차(RMSE)를 통해 계산한다. 평균 제곱 오차는 구체적으로 시간별 예측의 횟수가 r 일 때 테스트 데이터에 대한 식 (7)을 통해 계산된다.

$$E = \frac{1}{r} \frac{\sum_{j=1}^r \sqrt{(y_j - \hat{y}_j)^2}}{\sum_{j=1}^r y_j} \quad (7)$$

4.3 실험평가 및 분석

<Table 4>와 <Figure 4>는 본 연구에서 제안한 피크시간의 태양광 발전량 예측 모델의 계절에 따른 성능결과를 나타낸다. 본 연구에서 제안한 모델은 전반적으로 높은 성능을 보였다. 그러나 봄과 가을에는 여름과 겨울에 비해 하루 중 피크이전의 시간의 태양광 발전량과 피크시간의 태양광 발전량과의 차이가 많이 발생할 뿐만 아니라 태양광의 변화가 심하기 때문에 예측하기 더 어려운 계절로 구분된다. 따라서 본 연구에서 제안한 모델은 여름과 겨울에 평균 제곱 오차가 낮은 반면에 봄과 가을에 평균 제곱 오차가 높았다. 또한, 봄과 가을에는 특정 주에 따라 평균 제곱 오차가 많이 발생하였다.




<Figure 4> Performance Comparison Result Depending on Seasons

<Table 4> RMSE Results of The Proposed Model According to Seasons


	Seasons			
Weeks	Spring	Summer	Autumn	Winter
1	16.294	4.454	10.177	4.698
2	17.621	2.351	3.032	2.358
3	10.001	4.764	4.141	4.252
4	15.755	4.703	7.421	8.121

<Figure 5>는 태양광 발전량 변화에 대해 단기적인 관점에서 하루 중 피크이전의 태양광 발전량과 피크시간의 태양광 발전량의 변화 차이에 따라 본 연구에서 제안한 모델을 기반으로 성능을 평가한 것을 나타낸다.


<Figure 5>의 (a)에서 볼 수 있듯이, LSTM 기반의 태양광 발전량 예측 모델은 피크이전의 태양광 발전량과 피크시간의 태양광 발전량과의 변화 차이가 작았을 때 높은 성능을 보인다는 것을 알 수 있다. 반면에, (b), (c)와 같이, 피크시간의 태양광 발전량의 변화가 급격히 증가할 경우에는 예측의 정확도가 낮아지는 것을 확인하였다. 모든 경우에 대해 기존 모델에 비해 상당히 낮은 오류를 보인다. 특히, (c)와 같이 피크이전의 태양광 발전량의 정보가 거의 없고 피크시간의 태양광 발전량의 변화가 급격히 증가할 경우에는 예측의 정확도가 많이 낮아지는 경향을 볼 수 있었다. 그러나 전체적으로 LSTM 기반의 피크시간 태양광 발전량 예측 모델은 단기 및 장기적 관점에서 숨겨진 시계열 패턴과 정보를 학습함으로써 피크이전의 정보들만을 이용하여 단기 및 장기적 관점에서 피크시간의 태양광 발전량을 예측하는데 높은 성능을 보인다는 것을 알 수 있었다.



(a) When PV power outputs are similar
(Which 28, August)



(b) When PV power outputs rise
(Which 2, October)



(c) When PV power outputs rapidly rise
(Which 8, April)

〈Figure 5〉 Predicted PV power
Outputs in Peak Times
Results of The Proposed
Model

따라서 본 연구에서 제안한 실험을 통해 계절에 따라 태양광 발전량 예측의 성능을 평가하였다. LSTM 기반의 피크시간 태양광 발전량 예측 모델은 모든 계절에 대해 높은 성능을 보였다. 그러나 봄과 가을과 같이 태양광 발전량의 변화가 큰 계절에 대해서는 정확도가 떨어지는 경향성을 보였다.

그리고 피크이전의 태양광 발전량과 피크시간의 태양광 발전량이 변화하는 차이에 따라 비교한 결과, 변화가 차이가 적을 때는 높은 성능을 보였다. 반면에, 태양광 발전량의 차이 변화가 증가하거나 급격히 증가할 때에는 예측의 정확도가 낮아지는 것을 확인하였다. 그러나 본 연구에서 제안한 모델은 피크이전의 기후, 계절, 측정된 태양광 발전량 정보만을 이용하여 피크시간의 태양광 발전량을 예측하였고, 짧은 시간의 정보를 입력 값으로 이용하여 입력 값보다 긴 시간의 출력 값을 예측하였기 때문에 더 어려운 문제임에도 불구하고 단기 및 장기적 관점에서 본 연구에서 제안한 모델이 높은 성능을 보인다는 것을 실험을 통해 확인하였다. 따라서 학습 과정의 피크시간의 태양광 발전량을 정확하게 예측하기 위해서는 단기 및 장기적 관점에서 숨겨진 시계열 패턴 뿐만 아니라 관계성을 학습 할 수 있는 모델을 사용해야 하는 것이 필수적이라는 것을 확인하였다.

5. 결 론

본 연구에서는 피크시간 이전의 측정된 기후, 계절 정보, 태양광 발전량 정보를 이용하여 피크시간의 태양광 발전량을 예측할 수 있는

LSTM 기반의 태양광 발전량 예측 분석 기법을 제안하였다. 본 연구에서 제안한 모델의 성능을 평가하기 위해 계절에 따른 평가와 피크 이전의 태양광 발전량과 피크시간의 태양광 발전량과의 변화 차이에 따른 실험을 제시하였다. 실험을 통해 본 연구에서 제안한 모델은 미래의 기후 및 계절 정보를 이용하지 않고 출력 값보다 짧은 시간의 입력 값으로 긴 시간의 출력 값을 예측한다는 어려움에도 불구하고 단기 및 장기적 관점에서 높은 성능을 보였다. 따라서 피크시간의 태양광 발전량을 잘 예측하기 위해서는 단기 및 장기적 관점에서 피크시간의 태양광 발전량의 영향을 끼치는 과거의 데이터를 이용하여 예측하려는 태양광 발전량과의 숨겨진 시계열 관계들을 이해할 수 있도록 반복적으로 학습할 수 있는 모델이 필요하며, 학습 기반의 모델을 통한 피크시간의 태양광 발전량 예측이 필수적이라는 것을 확인하였다.

본 연구의 결과는 미래의 기후 및 계절 정보 예측 없이 피크시간의 태양광 발전량을 예측하기 때문에 특정 지역과 무관하게 본 연구에서 제안한 모델을 활용하여 실제 환경에서 적용할 수 있을 것이다. 또한, 태양광 발전량 시스템을 이용하고 있는 대규모 공정에서는 본 연구에서 제안한 모델을 활용하여 태양광 발전량을 예측함으로써 합리적인 경제성을 확보하고 발전소 운영 계획을 안정화할 수 있을 것이다.

향후 연구에서는 피크시간의 태양광 발전량 예측의 성능을 향상시키기 위해 추가적인 눈, 태풍, 기압과 같은 정보들을 활용하여 모델의 성능을 향상시킬 수 있는 연구가 필요하다.

References

- [1] Ahn, S., Kang, H., Cho, J., Kim T.-O., and Shin, D., "Forecasting Model Design of Fire Occurrences with ARIMA Models," *Journal of the Korean Institute for Gas*, Vol. 19, No. 2, pp. 20-28, 2015.
- [2] Ashraf, I. and Chandra, A., "Artificial Neural Network Based Models for Forecasting Electricity Generation of Grid Connected Solar PV Power Plant," *International Journal of Global Energy Issues*, Vol. 21, No. 1-2, pp. 119-130, 2004.
- [3] Bacher, P., Madsen, H., and Nielsen, H.A., "Online Short-term Solar Power Forecasting," *Solar Energy*, Vol. 83, No. 10, pp. 1772-1783, 2009.
- [4] Choi, J., Shin Y., and Lee, I.-W., "DER Energy Management System for Optimal Management of Grid-Connected Microgrids," *The Journal of Korean Institute of Communications and Information Sciences*, Vol. 42, No. 4, pp. 932-938, 2017.
- [5] Chan, S. C., Tsui, K. M., Wu, H. C., Hou, Y., Wu, Y. C., and Wu, F. F., "Load/Price Forecasting and Managing Demand Response for Smart Grids," *Proceedings of Methodologies and Challenges*, Vol. 29, No. 5, pp. 68-85, 2012.
- [6] Chattopadhyay, K., Kies, A., Lorenz, E., von Bremen, L., and Heinemann, D., "The Impact of Different PV Module Configurations on Storage and Additional Balancing

- Needs for A Fully Renewable European Power System,” *Journal of Renewable Energy*, Vol. 113, pp. 176–189, 2017.
- [7] Chung, W. H., Park, G., Gu, Y. H., Kim, S., Yoo, S. J., and J. Y., “City Gas Pipeline Pressure Prediction Model,” *The Journal of Society for e-Business Studies*, Vol. 23, No. 2, pp. 33–77, 2018.
- [8] De Giorgi, M. G., Malvoni, M., and Congedo, P. M., “Comparison of Strategies for Multi-step Ahead Photovoltaic Power Forecasting Models Based on Hybrid Group Method of Data Handling Networks and Least Square Support Vector Machine,” *Energy*, Vol. 107, pp. 360–373, 2016.
- [9] Da Silva Fonseca, Jr, J. G., Oozeki, T., Takashima, T., Koshimizu, G., Uchida, Y., and Ogimoto, K., “Use of Support Vector Regression and Numerically Predicted Cloudiness to Forecast Power Output of A Photovoltaic Power Plant in Kitakyushu, Japan,” *Proceedings of Photovoltaics: Research and Applications*, Vol. 20, No. 7, pp. 874–882, 2012.
- [10] Donahue, J., Anne Hendricks, L., Guadarrama, S., Rohrbach, M., Venugopalan, S., Saenko, K., and Darrell, T., “Long-term Recurrent Convolutional Networks for Visual Recognition and Description,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2625–2634, 2015.
- [11] Graves, A., “Generating Sequences With Recurrent Neural Networks,” *arXiv pre-print arXiv:1308.0850*, 2013.
- [12] Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., and Schmidhuber, J., “LSTM: A Search Space Odyssey,” *IEEE Transactions on Neural Networks and Learning Systems*, Vol. 28, No. 10, pp. 2222–2232, 2016.
- [13] Glorot, X. and Bengio, Y., “Understanding The Difficulty of Training Deep Feedforward Neural Networks,” *Proceedings of The Thirteenth International Conference on Artificial Intelligence and Statistics*, pp. 249–256, 2010.
- [14] Hoffmann, W., “PV Solar Electricity Industry: Market Growth and Perspective,” *Solar Energy Materials and Solar Cells*, Vol. 90, No. 18–19, pp. 3285–3311, 2006.
- [15] Iglesias, G., Kale, D. C., and Liu, Y., “An Examination of Deep Learning for Extreme Climate Pattern Analysis,” *Proceedings of International Workshop on Climate Informatics*, 2015.
- [16] Izgi, E., Öztöpal, A., Yerli, B., Kaymak, M.K., and Sahin, A. D., “Short-mid-term Solar Power Prediction by Using Artificial Neural Networks,” *Solar Energy*, Vol. 86, No. 2, pp. 725–733, 2012.
- [17] Jiahao, K., Jun, L., Qifan, L., Wanliang, F., Zhenhuan, C., Linlin, L., and Tieying, G., “Photovoltaic Power Forecasting Based on Artificial Neural Network and Meteorological Data,” *Proceedings of International Conference of IEEE Regional World Map*, pp. 1–4, 2013.

- [18] Jurasz, J. and Ciapała, B., "Solar - hydro Hybrid Power Station As A Way to Smooth Power Output and Increase Water Retention," *Solar Energy*, Vol. 173, pp. 675-690, 2018.
- [19] Li, Y., Su, Y., and Shu, L., "An ARMAX Model for Forecasting The Power Output of A Grid Connected Photovoltaic System," *Renewable Energy*, Vol. 66, pp. 78-89, 2014.
- [20] Lee, H. and Kim, H., "Deep Learning Based Prediction Method of Long-term Photovoltaic Power Generation Using Meteorological and Seasonal Information," *The Journal of Society for e-Business Studies*, Vol. 24, No. 1, pp. 1-16, 2019.
- [21] Maqsood, I., Khan, M. R., and Abraham, A., "An Ensemble of Neural Networks for Weather Forecasting," *Neural Computing and Applications*, Vol. 13, No. 2, pp. 112-122, 2004.
- [22] Ordóñez, F. and Roggen, D., "Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition," *Sensors*, Vol. 16, No. 1, 2016.
- [23] Park, J., Lee, C., and Kim, S., "Survey and Analysis of DR Resources Potential for Each Sectors," *Proceedings of The Korean Institute of Electrical Engineers*, pp. 180-181, 2012.
- [24] Rowlands, I. H., "Solar PV Electricity and Market Characteristics: Two Canadian Case-studies," *Renewable Energy*, Vol. 30, No. 6, pp. 815-834, 2005.
- [25] Sulaiman, S. I., Rahman, T. K. A., and Musirin, I., "Partial Evolutionary ANN for Output Prediction of a Grid-Connected Photovoltaic System," *International Journal of Computer and Electrical Engineering*, Vol. 1, No. 1, pp. 40-45, 2009.
- [26] Shaheen, N. I. and Ahmed, O., "Simple Methodology to Predict Local Temperature and Humidity," In *ASHRAE Transactions*, 1998.
- [27] Shi, J., Lee, W. J., Liu, Y., Yang, Y., and Wang, P., "Forecasting Power Output of Photovoltaic Systems Based on Weather Classification and Support Vector Machines," *IEEE Transactions on Industry Applications*, Vol. 48, No. 3, pp. 1064-1069, 2012.
- [28] Yona, A., Senjyu, T., Funabashi, T., Mandal, P., and Kim, C. H., "Optimizing Re-planning Operation for Smart House Applying Solar Radiation Forecasting," *Applied Sciences*, Vol. 4, No. 3, pp. 366-379, 2014.
- [29] Zeng, J. and Qiao, W., "Short-term Solar Power Prediction Using A Support Vector Machine," *Renewable Energy*, Vol. 52, pp. 118-127, 2013.
- [30] Zaremba, W., Sutskever, I., and Vinyals, O., "Recurrent Neural Network Regularization," *arXiv preprint arXiv:1409.2329*, 2014.
- [31] Zhou, Y., Wang, C., Wu, J., Wang, J., Cheng, M., and Li, G., "Optimal Scheduling of Aggregated Thermostatically Controlled Loads with Renewable Generation in the Intraday Electricity Market," *Applied Energy*, Vol. 188, pp. 456-465, 2017.

저 자 소 개



이동훈

(E-mail: dhlee@inu.ac.kr)

2016년

단국대학교 산업공학과 학사

2017년~2019년


인천대학교 산업경영공학과 석사

2019년~현재

인천대학교 산업경영공학과 박사과정

관심분야

산업인공지능, 딥러닝, 최적화, 소셜 네트워크 분석



김관호

(E-mail: khokim@inu.ac.kr)

2006년

동국대학교 정보시스템전공 학사

2012년

서울대학교 산업공학과 박사

2013년

경희대학교 연구박사

2014년~현재

인천대학교 산업경영공학과 교수

관심분야

산업인공지능, 딥러닝, 최적화, 소셜 네트워크 분석