

일기 예보와 예측 일사 및 일조를 이용한 태양광 발전 예측

Photovoltaic Generation Forecasting Using Weather Forecast and Predictive Sunshine and Radiation

신 동 하 · 박 준 호 · 김 창 복*
가천대학교 에너지 IT학과

Dong-Ha Shin · Jun-Ho Park · Chang-Bok Kim*

Department of Energy IT, Gachon University, Seongnam-daero, Sujeong-gu, Seongnam-si, Gyeonggi-do, 1342, Korea

[요 약]

무한한 에너지를 가진 태양광 발전은 기상 에 의존하기 때문에 발전량이 매우 간헐적이다. 따라서 태양광 발전량의 불확실성을 줄이고 경제성을 향상시키기 위하여 정확한 발전량 예측기술이 필요하다. 기상청은 3일간 기상정보를 예보하지만 태양광 발전 예측에 높은 상관관계가 있는 일조량과 일사량은 예보하지 않는다. 본 연구에서는 기상청에서 3일간 예보하는 기상요소인 기온, 강수량, 풍향, 풍속, 습도, 운량 등을 이용하여, 일조 및 일사량을 예측하였으며, 예측된 일사 및 일조량을 이용하여, 실시간 태양광 발전량을 예측하는 딥러닝 모델을 제안하였다. 결과로서 예측된 기상요소로 발전량을 예측하는 모델보다 제안 모델이 MAE, RMSE, MAPE 등의 오차율 지표에서 더 좋은 결과를 보여주었다. 또한, 기계 학습의 한 종류인 서포트 벡터 머신을 사용하는 것보다 DNN을 사용하는 것이 더 낮은 오차율 지표를 보여주었다.

[Abstract]

Photovoltaic generation which has unlimited energy sources are very intermittent because they depend on the weather. Therefore, it is necessary to get accurate generation prediction with reducing the uncertainty of photovoltaic generation and improvement of the economics. The Meteorological Agency predicts weather factors for three days, but doesn't predict the sunshine and solar radiation that are most correlated with the prediction of photovoltaic generation. In this study, we predict sunshine and solar radiation using weather, precipitation, wind direction, wind speed, humidity, and cloudiness which is forecasted for three days at Meteorological Agency. The photovoltaic generation forecasting model is proposed by using predicted solar radiation and sunshine. As a result, the proposed model showed better results in the error rate indexes such as MAE, RMSE, and MAPE than the model that predicts photovoltaic generation without radiation and sunshine. In addition, DNN showed a lower error rate index than using SVM, which is a type of machine learning.

Key word : Solar photovoltaic generation forecast, Deep learning, Artificial neural network, Support vector machine.

<https://doi.org/10.12673/jant.2017.21.6.643>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 8 November 2017; Revised 7 December 2017

Accepted (Publication) 29 December 2017 (30 December 2017)

*Corresponding Author ; Chang-Bok Kim

Tel : +82-10-8908-3946

E-mail : cbkim@gachon.ac.kr

I. 서론

최근 화석연료에 대한 수요가 증가하면서 자원고갈과 가격 상승 등의 문제가 나타나고 있다. 또한 화석연료가 지구온난화를 일으키는 주요 원인으로 지적되어 사용량이 많은 국가에게 불이익을 주기 때문에, 화석연료의 사용을 줄이려는 노력이 필요하다[1]-[2]. 신재생 에너지는 자원이 무한하고, 이산화탄소와 같은 오염물질의 배출이 적어 환경 친화적이며, 화석연료에 비해 고르게 분포한다. 그러나 초기투자비와 발전단가가 높고, 설치장소가 한정적이며, 에너지 밀도가 낮아 큰 설치면적이 필요하고, 전력생산량이 기상상태에 의존하기 때문에 발전량 예측에 어려움이 있다.

태양광 발전은 전체 신재생 에너지의 80% 이상을 차지하고 2015년 10월 기준 국내 신재생에너지 발전소의 개수는 태양광 발전소가 13,503개 규모이며, 계속 증가하는 추세이다[3]. 태양광 발전은 타 신재생 에너지와 마찬가지로 기상상태에 따라서 출력이 매우 간헐적이며, 출력의 조정이 어려워 사전에 발전계획을 수립하기 어렵다. 따라서 태양광 발전의 출력의 불확실성을 줄이고 태양광 발전의 경제성을 향상시키기 위하여 향후 태양광 발전의 높은 정확도의 예측기술 활용이 필수적이다[4].

태양광 발전예측은 장기예측과 단기예측이 있다. 장기예측은 태양광 발전소의 초기 투자비용이 높기 때문에, 장기적으로 안정적인 발전수익을 판단하여 투자 계획에 이용한다. 단기예측은 태양광 발전소의 효율적인 운영과 다른 전력계통과 안정적인 연계에 이용한다. 단기예측은 실시간으로 발전량을 예측하는 초단기 예측, 다음날인 24시간 앞의 발전량을 예측하는 연구 등이 있다[5]. 태양광 발전을 예측하기 위한 방법으로, ELM(extreme learning machine), SVM(support vectors machine), 신경망 등 기계학습에 대한 연구가 활발히 진행되고 있다 [6]-[8]. 기계학습은 컴퓨터가 데이터를 학습하여 지능을 획득하는 빅 데이터의 핵심기술이다. 특히, 산업혁명 4.0 시대의 도래로 에너지 기술과 ICT(information and communication technology) 기술이 융합되면서, 신경망 모델인 딥러닝(deep learning)을 이용하여, 태양광 발전예측에 대한 연구가 진행되고 있다[9]-[10].

본 연구는 2013년부터 2015년까지의 기상청의 일별 기상 데이터와 태양광 발전소의 발전량 데이터를 이용하여 태양광 발전량 실시간 예측 딥러닝 모델을 제안하였다. 기상데이터는 영암 발전소 근처의 목포 기상청의 일별 기상 데이터이며, 발전량 데이터는 영암 태양광 발전량이다. 기상청은 3일간 기상정보를 예보하지만 태양광 발전예측에 가장 상관관계가 높은 일조량과 일사량은 예보하지 않는다. 따라서 본 연구에서는 기상청에서 3일간 예보하는 기상요소인 기온, 강수량, 풍향, 풍속, 습도, 운량 등을 이용하여, 일조 및 일사량을 예측하였으며, 예측된 일사 및 일조량을 이용하여, 실시간 태양광 발전량을 예측하였다. 예측을 위한 기계학습은 예측요소를 분석하기 위해 통계 오픈 소스인 R을 이용하였으며, DNN(deep neural network) 딥러

닝 네트워크 구축하기 위해 구글의 텐서플로우를 이용하였다.

본 논문은 2장에서 관련연구로서 태양광 발전량 예측요소와 기계학습에 대해서 서술하였다. 또한, 3장에서 태양광 발전 예측모델을 제안하였으며, 4장에서 실험결과를 나타내고 마지막으로 결론에 대해서 서술하였다.

II. 태양광 발전 예측과 딥러닝

2-1 일사 및 일조 예측

태양광 발전은 기상요소, 지리요소, 설비요소 등에 의해 발전량에 영향을 끼친다. 태양전지는 태양의 복사에너지에 의해 전기를 생산하기 때문에, 일사량과 일조량이 매우 중요한 요소이며, 태양전지가 반도체이기 때문에, 적당한 온도를 유지해야 한다. 지리요소는 태양의 고도에 관계가 있는 위도, 경도 및 해발높이 등이 있다. 설비요소는 태양의 움직임에 따라 패널 고정형, 고정 가변형, 추적형 등이 있으며, 축전지 및 전력변환장치의 효율 등이 있다. 특히, 태양광 발전은 기상상태에 따라서 그 출력이 매우 간헐적이며, 대부분의 기상요소는 태양광 발전에 가장 많은 영향을 주는 요소라 할 수 있다. 따라서 태양광 발전의 출력에 대한 불확실성의 영향을 줄이고 태양광 발전의 경제성을 향상시키기 위하여 향후 태양광 발전단지에서 기상요소를 이용한 태양광 출력 예측기술 활용이 필수적이다. 표 1에 태양광 발전량과 기상요소의 상관관계에 대해서 나타냈다. 표 1에서 전운량을 제외한 나머지 기상요소는 기상대에서 예보되는 데이터를 사용하였으나, 전운량의 경우 태양광 발전기가 발전하는 평균 시간인 6시부터 18시 사이의 데이터의 평균을 사용하였다.

표 1. 발전량과 기상요소의 상관관계
Table 1. Relation of power generation and weather forecasting factors.

Item	2013	2014	2015	Average
Avg. Temp	0.2168	0.1541	0.1949	0.188
Min. Temp	0.1454	0.0625	0.0975	0.101
Max. Temp	0.2971	0.2692	0.3108	0.291
Precip.	-0.35	-0.471	-0.417	-0.398
Wind Speed	-0.098	-0.035	-0.039	-0.054
Rel. Humidity	-0.483	-0.476	-0.419	-0.449
Atmos. Pressure	0.0058	0.052	-0.031	0.008
Cloud	-0.804	-0.817	-0.783	-0.801
Sunshine	0.9154	0.9211	0.9165	0.918
Radiation	0.9222	0.9200	0.9262	0.922




그림 1. 2015년 일조 예측
Fig. 1. Forecasting of 2015 sunshine.




그림 2. 2015년 일사 예측
Fig. 2. Forecasting of 2015 solar radiation.

본 연구는 R의 신경망 패키지를 이용하여 기상청에서 제공하는 모든 기상요소에 대해서 일조량과 일사량을 예측하였다. 그 결과 기상대에서 예보하는 평균기온, 최저기온, 최고기온, 강수량, 풍속, 습도, 전운량 등의 기상요소를 이용하여 일사량과 일조량을 예측한 결과와 발전량과의 상관관계가 비교적 높았으며, 오차율이 적었다. 그림 1과 그림 2에 기상청에서 예보하는 기상요소를 이용하여 2015년의 일사량과 일조량 예측결과에 대한 그래프를 나타냈다.

2-2 기계학습

기계학습은 컴퓨터가 데이터를 학습하여 지능을 획득하는 학문분야이며, 빅 데이터의 핵심 기술 분야이다. SVM은 인공지능의 기계학습 분야 중 하나로서, 주로 분류와 회귀 분석을 위해 사용되며, 패턴인식, 자료 분석을 위한 지도학습 모델이다. SVM은 특징에 따라 서로 유사한 그룹끼리 초평면으로 나누는 것이다. 초평면은 다음과 같이 나타낼 수 있다.

$$H_1 : W^T x_i + w_0 \geq 1 \text{ for } y_i = +1 \quad (1)$$

$$H_2 : W^T x_i + w_0 \leq -1 \text{ for } y_i = -1 \quad (2)$$

$$y_i (W^T x_i + w_0) \geq 1, \forall i \quad (3)$$

여기서 W^T 는 초평면의 법선벡터이며, x_i 는 실수벡터이면서 입력 데이터 값이다. y_i 는 x_i 가 어떤 클래스에 속했는지를 나타내는 값으로 1 혹은 -1의 값을 가진다.

초평면 H_1 과 H_2 위에 위치하는 모든 튜플은 위 식을 만족한다. 비선형 SVM은 선형적으로 분리할 수 없는 데이터에 적용할 수 있다. 비선형 SVM은 원 데이터를 비선형 매핑을 통해 고차원 공간으로 변환한다. 예를 들어 2차원에서 3차원으로 한 차원 높게 변환하였을 때 선형 분리 초평면을 갖게 된다. 그러나 고차원으로 비선형 매핑을 하게 되면 초평면의 최대마진을 구하기 위한 비용이 많이 들게 된다. 이를 해결하기 위해 커널 트릭을 사용하며, 데이터 튜플을 고차원으로 보낸 뒤 벡터의 내적을 계산하는 것과 내적을 한 뒤 고차원으로 보내는 결과가 같다는 원리를 이용한다.

인공신경망은 인간의 뇌 구조를 모방한 기계학습으로, 기존의 인공신경망은 뇌의 뉴런과 유사한 형태인 시그모이드 (sigmoid) 비선형 함수를 사용하였다. 시그모이드 활성화 함수는 지수함수 특징에 의한 기울기 사라짐 (gradient descent), 지역 최솟값 (local minima) 등과 같은 문제와 이에 따른 학습시간의 길어짐의 문제점이 있었다. 또한, 가중치 초기화 문제와 학습 데이터 셋에 너무 가깝게 맞추어 학습하는 과적합 (overfitting)의 문제가 있었다. 딥러닝은 ReLu (rectified linear unit) 활성화 함수를 사용하여, 심층에 의한 기울기 사라짐, 지역 최솟값 문제를 해결한다. 또한, Xavier 초깃값 등과 같은 가중치 초기화 기법을 이용해 가중치 초기화 문제를 해결하고, 과적합 방지를 위해 중간층 노드를 강제로 없애는 드롭아웃 (drop out) 방식을 이용하여 중간층을 깊게 한 심층 신경망이다 [9]. 예측을 위한 딥러닝은 DNN, CNN (convolution neural network), RNN (recurrent neural network) 등이 있다. DNN은 입출력 패턴을 인간이 직접 선택해야 하며, 패턴을 그대로 학습하기 때문에, 패턴에 따라 예측결과가 차이가 있다. CNN은 영상의 특징을 추출하는 컨볼루션과 DNN이 결합된 형태의 딥러닝이다 [10]. 또한, RNN은 동일한 신경망을 여러 개 복사하여 병렬로 체인 구조로 연결함으로써, 이전 신경망의 학습결과를 현재 신경망의 학습에 사용하기 때문에, 시계열 데이터를 처리하는데 효과적이다 [11]-[13].

표 2에 4일 동안의 운량과 발전량에 대한 상관관계를 나타냈다. 표 2에서 시간별 및 일별마다 운량의 변화가 심하기 때문에, 운량에 매우 상관관계가 높은 일조량, 일사량, 태양광 발전량들의 변화가 운량에 따라 심하게 변동한다. 이와 같이 당일 발전량과 다음날 발전량과 상관관계가 거의 없기 때문에, 시계열 데이터 예측에 적합한 RNN 딥러닝 네트워크로 예측이 어려우며, 각각의 일별 입력 패턴만으로 예측이 가능한 DNN으로 딥러닝 네트워크가 효과적이다.

표 2. 운량과 발전량의 상관관계

Table 2. Relation of cloudiness and power generation.

Item	Yester day	Today	Tomorrow	D. A. Tomorrow
Cloud	0.35160	1	0.35125	0.12707
Power Generation	0.38311	1	0.38282	0.18989

III. 예측 모델

기상청은 기온, 강수량, 풍향, 풍속, 습도, 운량 등을 실시간으로 예보하지만 태양광 발전예측에 가장 상관관계가 높은 일조량과 일사량은 예보하지 않는다. 따라서 본 연구는 기상청에서 실시간으로 예보하는 기상데이터만을 이용하여, 일조량과 일사량을 예측하고, 예측된 일조량과 일사량을 이용하여, 태양광 발전을 예측하는 딥러닝 모델을 제안하였다. 그림 3에 제안 발전량 예측모델의 전체 구조에 대해서 나타냈다. 제안모델은 평균기온(X1), 최저기온(X2), 최고기온(X3), 강수량(X4), 풍향(X5), 풍속(X6), 습도(X7), 운량(X8) 등을 딥러닝 네트워크의 입력변수로 하여, 일조(Y1) 및 일사(Y2) 예측을 하였다. 또한, 기상 예보 데이터와 예측된 일조량과 일사량을 입력변수로 하여 태양광 발전예측(Y3)을 하였다. 그림 4에 일사 및 일조량을 예측하기 위한 학습 및 테스트 데이터 구조에 대해서 나타냈다.

2013년도 일조 및 일사예측을 위해서 학습 데이터는 2013년을 제외한 2014년, 2015년 데이터를 사용하였으며, 테스트 데이터는 2013년도 데이터로 하였다. 또한, 2014년도 일조 및 일사예측을 위해서 학습 데이터는 2014년을 제외한 2013년, 2015년 데이터를 사용하였으며, 테스트 데이터는 2013년도 데이터로 하였다. 마지막으로 2015년도 일조 및 일사예측을 위해서 학습 데이터는 2015년을 제외한 2013년, 2014년 데이터를 사용하였으며, 테스트 데이터는 2015년도 데이터로 하였다.

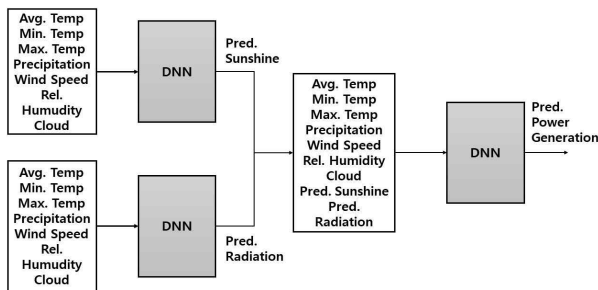


그림 3. 발전량 예측 제안 모델
 Fig. 3. Model of power generation forecasting.

Train Data	2014 year	2013 year	2013 year
	2015 year	2015 year	2014 year
Test Data	2013 year	2014 year	2015 year

그림 4. 일조 및 일사 예측 데이터 구조
 Fig. 4. Data structure of sunshine and solar radiation forecasting.

그림 5와 같이 일조 및 일사 예측결과를 통해 발전량 예측은 월별 발전량 예측과 임의의 일별 발전량 예측을 위해 두 가지 데이터 구조로 하였다. 그림 5에 발전량 예측을 위한 데이터 구조를 나타냈다.

월별 발전량 예측을 위한 데이터 구조는 2015년도에서 임의의 달을 테스트 데이터로 하였으며, 그 외의 모든 데이터를 학습 데이터로 하였다. 또한, 일별 발전량 예측을 위한 데이터 구조는 2013년부터 2015년 데이터 중 10개의 임의의 데이터를 추출하여, 테스트 데이터로 사용하였고, 나머지 모든 데이터를 학습 데이터로 사용하였다. 본 연구에서는 보다 효율적인 데이터 학습과 예측을 향상을 위해, 다양한 딥러닝 네트워크 구축이 가능한 텐서플로우를 이용하여, 보다 깊게 신경망을 구축하였다. 그림에 6과 7에 일조, 일사, 발전량 예측을 위한 DNN 예측모델에 대해서 나타냈다.




그림 5. 발전량 예측 데이터 구조
 Fig. 5. Data structure of power generation forecasting.

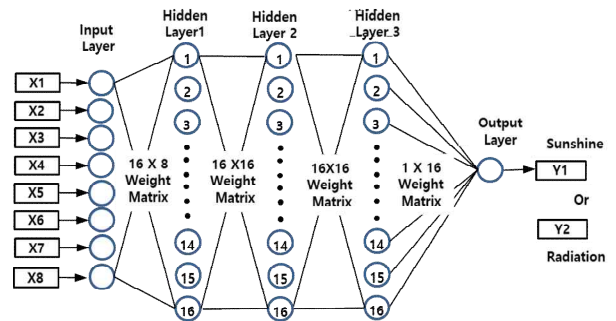


그림 6. 일조 및 일사 예측모델
 Fig. 6. Model of sunshine and solar radiation forecasting.




그림 7. 발전량 예측모델
 Fig. 7. Model of power generation forecasting.

본 연구는 딥러닝의 학습율을 0.001로 하였으며, 입력 층은 일사와 일조예측을 위해 8 노드 그리고 태양과 발전량 예측을 위해서 10 노드로 하였다. 또한, 중간층은 각 층마다 16 노드로 하여 3층으로 설정하였으며, 출력 층은 1 노드이다. 이러한 딥러닝 모델이 가능하도록 활성화 함수로 ReLu함수를 사용하였고, 학습율과 학습속도를 높이기 위해 Xavier 초기화 함수로 가중치를 초기화 하였다. 또한, 최적화 알고리즘으로 Adam Optimizer를 사용하였다.

IV. 실험 결과

본 연구의 실험환경은 Linux Ubuntu 16.04 LTS 운영체제와 Mac OS High Sierra를 기반으로 Python 2.7, 통계 오픈 소스인 R, Tensorflow 1.2를 사용하였다. 본 연구는 일조와 일사예측을 위해서 영암 발전소와 근접한 목포 기상청의 2013년부터 2015년도까지의 일별 기상데이터를 이용하였다. SVM은 Linear, Polynomial, Radial 총 3개의 커널 트릭 중 가장 좋은 결과를 보인 Linear와 Radial을 사용했으며, DNN은 3층의 은닉 층을 사용하였다.

태양광 발전예측을 위한 모든 기상요소는 데이터 값의 크기가 모두 다르기 때문에, 데이터 범위를 일치시키거나 분포를 유사하게 만들어야한다. 또한, 인공지능은 입출력 데이터의 크기가 작아야 학습이 효과적이기 때문에, 모든 데이터를 다음과 같이 정규화 하였다.

$$\tilde{d}_i = \frac{d_i - \min(1:d)}{\max(1:d) - \min(1:d)} \quad (4)$$

여기서 d_i 는 각 요소 데이터, $\min(1:d)$ 은 각 요소 중 가장 작은 값, $\max(1:d)$ 은 각 요소 중 가장 큰 값을 나타낸다.

본 연구는 다음과 같이 절대 평균오차(mean absolute error), 평균 제곱근오차(root mean square error)와 평균 절대오차(mean absolute percentage error)를 사용하였다. MAE와 RMSE는 목표 값을 정규화해서 실험했으며, MAPE는 정규화 할 경우 0의 값이 생겨 값이 무한대가 되기 때문에 실측 데이터를 사용하였다. 임의의 일별 발전량 예측을 제외한 모든 실험은 5번을 실험한 것들의 평균이다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (actual - predict_i)^2}{n}} \quad (6)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - f_i}{y_i} \right| \quad (7)$$

표 3. 실시간 예보 기상 데이터를 이용한 월별 발전량 예측결과
Table 3. Results of power generation forecasting of each months with real time forecasting weather factors.

		April	July	October	Average
DNN	MAE	0.120	0.073	0.152	0.12
	RMSE	0.154	0.098	0.178	0.14
	MAPE	27.55	17.28	42.99	29.27

표 4. 실시간 예보 기상 데이터를 이용한 일별 발전량 예측결과
Table 4. Results of power generation forecasting of random days with real time forecasting weather factors.

		Ran. 1	Ran. 2	Ran.3	Average
DNN	MAE	0.110	0.093	0.106	0.10
	RMSE	0.119	0.112	0.156	0.13
	MAPE	27.76	30.63	20.28	26.22

표 3과 4에 기상청에서 실시간 예보가 되지 않는 일사와 일조를 제외하고 실시간 예보가 되는 기상 데이터인 기온, 강수량, 풍향, 풍속, 습도, 운량 등만을 사용한 발전량 예측결과에 대해서 나타냈다. 실험은 3층의 은닉 층을 사용한 DNN을 사용하였다.

표 5. 일조량 예측결과
Table 5. Results of sunshine forecasting.

		2 0 1 3 year	2 0 1 4 year	2 0 1 5 year	Average
SVM (linear)	MAE	0.114	0.094	0.103	0.10
	RMSE	0.144	0.121	0.130	0.13
	MAPE	159.1	123.1	167.8	150.00
SVM (Radial)	MAE	0.091	0.076	0.092	0.09
	RMSE	0.120	0.101	0.123	0.11
	MAPE	96	92.2	118.1	102.10
3 layer	MAE	0.085	0.074	0.086	0.08
	RMSE	0.114	0.098	0.115	0.11
	MAPE	66.7	76.9	60.1	67.90




그림 8. 2015년 5월 일조량 예측
Fig. 8. Forecasting of sunshine in May 2015.

표 5에 2013년도부터 2015년도까지의 일조량 예측결과에 대해서 나타냈고, 그림 8에 2015년도 5월에 대한 예측결과를 그래프로 나타냈다. 일조량 예측에서 SVM Linear의 MAE 평균은 0.10, RMSE의 평균은 0.13, MAPE의 평균은 150.00으로 가장 좋지 않은 예측율을 보였다. SVM Radial에서는 MAE 평균은 0.09, RMSE의 평균은 0.11, MAPE의 평균은 102.10으로 SVM Linear 보다 전체적으로 조금 좋은 예측결과를 보였다. DNN의 경우 MAE 평균은 0.08, RMSE의 평균은 0.11, MAPE의 평균은 67.90으로 가장 좋은 예측결과를 보였다.

표 6에 2013년도부터 2015년도까지의 일사 예측결과에 대해서 나타냈고, 그림 9에 2015년도 5월에 대한 예측결과를 그래프로 나타냈다. 일사량 예측에서 SVM Linear의 MAE 평균은 0.12, RMSE의 평균은 0.14, MAPE의 평균은 35.70으로 가장 좋지 않은 예측결과를 보였다. SVM Radial에서는 MAE 평균은 0.11, RMSE의 평균은 0.13, MAPE의 평균은 31.43으로 SVM Linear 보다 조금 향상된 예측결과를 보였다. DNN의 경우 MAE 평균은 0.10, RMSE의 평균은 0.13, MAPE의 평균은 29.73으로 가장 좋은 예측결과를 보였다.

표 6. 일사량 예측결과

Table 6. Results of solar radiation forecasting.

		2013 year	2014 year	2015 year	Average
SVM (linear)	MAE	0.119	0.111	0.117	0.12
	RMSE	0.146	0.137	0.140	0.14
	MAPE	33.1	30.1	43.9	35.70
SVM (Radial)	MAE	0.103	0.096	0.117	0.11
	RMSE	0.132	0.123	0.145	0.13
	MAPE	25.9	27.6	40.8	31.43
3 layer	MAE	0.105	0.095	0.111	0.10
	RMSE	0.132	0.119	0.137	0.13
	MAPE	25.2	26.5	37.5	29.73




그림 9. 2015년 5월 일사량 예측

Fig. 9. Forecasting of solar radiation in May 2015.

표 7. 월별 발전량 예측결과

Table 7. Results of power generation forecasting in each months.

		April	July	October	Average
SVM (linear)	MAE	0.109	0.1	0.136	0.12
	RMSE	0.15	0.126	0.169	0.15
	MAPE	24.6	21.6	45.9	30.70
SVM (Radial)	MAE	0.111	0.076	0.166	0.12
	RMSE	0.148	0.102	0.188	0.15
	MAPE	26.3	17.3	44.7	29.43
3 layer	MAE	0.107	0.065	0.132	0.10
	RMSE	0.134	0.086	0.160	0.13
	MAPE	24.4	14.9	47.9	29.07

표 7에 2013년도부터 2015년도까지의 월별 발전량 예측결과에 대해서 나타냈고, 그림 10에 2015년도 4월과 7월 예측결과를 그래프로 나타냈다.

월별 발전량 예측결과에서 SVM Linear의 MAE 평균은 0.12, RMSE의 평균은 0.15, MAPE의 평균은 30.70이다. SVM Radial에서는 MAE 평균은 0.12, RMSE의 평균은 0.15, MAPE의 평균은 29.43으로 SVM Linear과 MAE와 RMSE는 같았지만, MAPE에서 좀 더 좋은 결과를 보였다. DNN의 경우 MAE 평균은 0.10, RMSE의 평균은 0.13, MAPE의 평균은 29.07로 가장 좋은 예측결과를 보였다.





그림 10. 월별 발전량 예측 그래프

Fig. 10. Forecasting of power generation in each months.

표 8. 임의의 일별 발전량 예측결과

Table 8. Results of power generation forecasting with random days.

		Ran. 1	Ran. 2	Ran.3	Average
SVM (linear)	MAE	0.133	0.129	0.117	0.13
	RMSE	0.162	0.147	0.131	0.15
	MAPE	18.1	48.1	22	29.40
SVM (Radial)	MAE	0.061	0.099	0.067	0.08
	RMSE	0.069	0.134	0.087	0.10
	MAPE	16.6	44.33	43.5	34.81
3 layer	MAE	0.055	0.08	0.07	0.07
	RMSE	0.068	0.096	0.083	0.08
	MAPE	15.8	13.9	19.2	16.30




그림 11. 임의의 일별 발전량 예측

Fig. 11. Forecasting of power generation with random days.

표 8에 임의의 발전량 예측결과에 대해서 나타냈고, 그림 11에 임의의 발전량 예측결과를 그래프로 나타냈다.

임의의 일별 발전량 예측에서는 SVM Linear의 MAE 평균이 0.13, RMSE의 평균은 0.15, MAPE의 평균은 29.40이다. SVM Radial에서는 MAE 평균은 0.08, RMSE의 평균은 0.10, MAPE의 평균은 34.81로 MAPE는 SVM Radial 보다 SVM Linear이 좋았지만, MAE와 RMSE는 SVM Linear이 SVM Radial보다 좋았다. DNN의 경우 MAE 평균은 0.07, RMSE의 평균은 0.08, MAPE의 평균은 16.30으로 가장 좋은 예측결과를 보였다.

연구 결과, 실시간으로 예측되는 기상요소인 기온, 강수량, 풍향, 풍속, 습도, 운량 등으로만 발전량을 예측하는 모델 보다 예측 요소를 바탕으로 일사와 일조를 예측한 뒤, 이를 통해 발전량을 예측하는 모델이 더 좋은 예측율을 보여주었다. 그러나 10월의 발전량 예측에서 일사, 일조를 포함한 모델이 예측율이 다소 증가되는 것을 보여주었다. 또한, 제안된 모델을 사용해 Linear와 Radial 등의 커널 트릭을 사용한 SVM과 일조, 일사를 포함하지 않은 3층의 은닉 층을 사용한 DNN의 MAE, RMSE, MAPE가 비슷했다. 하지만 제안된 모델을 사용해 3층의 은닉 층을 사용한 DNN의 경우, 실험 환경에 따라서 조금씩 차이가 있지만, 평균적으로 가장 적은 MAE, RMSE, MAPE 수치를 보

여주었다.

또한 제안모델은 임의의 발전량 예측결과 대부분의 예측 결과가 우수했으며, 기상청에서 실시간으로 예보되는 기상데이터만을 이용하여 실시간 태양광 발전량 예측이 가능함을 제시하였다.

V. 결론 및 향후 과제

본 연구는 2013년부터 2015년까지의 기상청에서 예보하는 시간별 기상 데이터와 영암 태양광 발전소의 시간별 발전량 데이터를 이용하여 태양광 발전량 예측모델을 제안하였다. 본 연구를 통해 기존 예보 데이터인 기온, 강수량, 풍향, 풍속, 습도, 운량 등으로만 발전량을 예측하는 것보다 제안 모델의 예측율이 향상된 것을 알 수 있다. 그러나 월별 발전량 예측의 10월 실험에서 제안된 모델의 예측율이 감소하였다. 이것은 태양광 패널이 온도에 영향을 받기 때문에 추운 날씨에는 태양광 발전량이 일사 혹은 일조량과 상관관계가 상대적으로 감소한 것으로 예측된다. 따라서 태양광 발전량 예측의 오차율을 줄이기 위해서는 태양광 패널의 특성을 고려한 추가적인 입력 예측 요소를 추가하거나 온도나 혹은 계절에 따른 추가적인 예측 모델에 대한 연구가 필요하다.

Acknowledgments

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20174030201470)

References

- [1] S. M. Lee, and Y. H. Chun, "Assessment of optimal constitution rate of wind turbine and photovoltaic sources for stable operation of microgrid," *The transactions of The Korean Institute of Electrical Engineers*, Vol. 59, No. 2, pp. 272-276, Feb.2010.
- [2] B. H. Lee, "A study on simplified robust optimal operation of microgrids considering the uncertainty of renewable generation and loads," *The transactions of The Korean Institute of Electrical Engineers*, Vol. 66, No. 3, pp. 513-521, May2017
- [3] M. H. Seo, G. S. Kim, and S. H. Kim, "A development of the solar position algorithm for improving the efficiency of photovoltaic power generation," in *Proceedings of KIIT Summer Conference*, pp. 46-51, Jun.2009.

- [4] J. J. Song, Y. S. Jeong, and S. H. Lee, "Analysis of prediction model for solar power generation," *Journal of Digital Convergence*, Vol. 12, No. 3, pp. 243-248, Mar. 2014.
- [5] K. D. Kim, "The development of the short-term predict model for solar power generation," *The Korea Solar Energy Society*, Vol. 33, No. 6, pp. 62-69, Dec.2013.
- [6] C. S. Lee, and P. S. Ji, "Development of daily PV power forecasting models using ELM," *The Transactions of the Korean Institute of Electrical Engineers*, Vol. 64P, No. 3, pp. 164-168, Sep. 2015
- [7] K. H. Lee, W. J. Kim, "Forecasting of 24_hours ahead photovoltaic power output using support vector regression," *Journal of Korean Institute of Information Technology*, Vol. 14, No. 3, pp. 175-183, May 2016.
- [8] D. J. Lee, J. P. Lee, C. S. Lee, J. Y. Lim, and P. S. Ji, "Development of PV power prediction algorithm using adaptive neuro-fuzzy model," *The Transactions of the Korean Institute of Electrical Engineers*, Vol. 64, No. 4, pp. 246-250, Dec.2015.
- [9] W. C. Cha, J. H. Park, U. R. Cho, and J. C. Kim", "Design of Generation Efficiency Fuzzy Prediction Model using Solar Power Element Data," *The transactions of The Korean Institute of Electrical Engineers*, Vol. 63, No. 10, pp. 1423-1427, Oct.2014.
- [10] S. M. Lee, and W. J. Lee, "Development of a system for predicting photovoltaic power generation and detecting defects using machine learning," *KIPS Transactions on Computer and Communication Systems*, Vol. 5, No. 10, pp.353-360, Oct.2016.
- [11] A. Yona, T. Senjyu, T. Funabashi, P. Mandal, and C. H. Kim, "Decision technique of solar radiation prediction applying recurrent neural network for short-term ahead power output of photovoltaic system," *Smart Grid and Renewable Energy*, pp. 32-38, Apr.2013
- [12] F. A. Gers, N. N. Schraudolph, and J. Schmidhuber, "Learning precise timing with LSTM recurrent networks," *Journal of Machine Learning Research* 3, pp. 115-143, Mar.2002.
- [13] Christopher Olah, Understanding LSTM Networks, Github blog[Internet]. available:<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>



신 동 하 (Dong-Ha Shin)

2016 2월 : 가천대학교 에너지IT학과 학사 졸업 (공학사)
2016년 3월 ~ 현재 : 가천대학교 IT융합공학과 에너지IT전공 석사 과정
※관심분야 : 딥러닝, 빅 데이터, IOT, 로봇제어, 로봇 액추에이터



박 준 호 (Jun-Ho Park)

2015 8월 : 가천대학교 에너지IT학과 학사 졸업 (공학사)
2015년 9월 ~ 현재 : 가천대학교 IT융합공학과 에너지IT전공 석사 과정
※관심분야 : 전력전자, 로봇 제어, 딥러닝, 빅 데이터, IOT,



김 창 복 (Chang-Bok Kim)

1986년 2월 : 단국대학교 전자공학과 졸업(공학사)
1989년 2월 : 단국대학교 전자공학과 (공학석사)
2009년 2월 : 인천대학교 컴퓨터 공학과(공학박사)
1994년 ~ 현재 : 가천대학교 IT대학 에너지 IT학과 교수
※관심분야 : 데이터 마이닝, 딥러닝, 강화학습, 사물인터넷