

## 지도학습에서 다양한 입력 모델에 의한 초단기 태양광 발전 예측 Forecasting of Short Term Photovoltaic Generation by Various Input Model in Supervised Learning

장진혁 · 신동하 · 김창복\*  
가천대학교 에너지 IT학과

Jin-Hyuk Jang · Dong-Ha Shin · Chang-Bok Kim\*  
Department of Energy IT, Gachon University, 1342, Gyeonggi-do, 13120, Korea

### [요 약]

본 연구는 기온, 강수량, 풍향, 풍속, 습도, 운량, 일조, 일사 등 시간별 기상 데이터를 이용하여, 일사 및 일조 그리고 태양광 발전 예측을 하였다. 지도학습에서 입력패턴은 예측에서 가장 중요한 요소이지만 인간이 직접 결정해야하기 때문에, 반복적인 실험에 의해 결정해야 한다. 본 연구는 일사 및 일조 예측을 위하여 4가지 모델의 입력 패턴을 제안하였다. 또한, 예측된 일조 및 일사 데이터와 전라남도 영암 태양광 발전소의 발전량 데이터를 사용하여 태양광 발전량을 예측하였다. 실험결과 일조 및 일사 예측에서 모델 4가 가장 예측결과가 우수했으며, 모델 1에 비해 일조의 RMSE는 1.5배 정도 그리고 일사의 RMSE는 3배 정도 오차가 줄었다. 태양광 발전예측 실험결과 일조 및 일사와 마찬가지로 모델 4가 가장 예측결과가 좋았으며, 모델 1 보다 RMSE가 2.7배 정도 오차가 줄었다.

### [Abstract]

This study predicts solar radiation, solar radiation, and solar power generation using hourly weather data such as temperature, precipitation, wind direction, wind speed, humidity, cloudiness, sunshine and solar radiation. I/O pattern in supervised learning is the most important factor in prediction, but it must be determined by repeated experiments because humans have to decide. This study proposed four input and output patterns for solar and sunrise prediction. In addition, we predicted solar power generation using the predicted solar and solar radiation data and power generation data of Youngam solar power plant in Jeollanamdo . As a experiment result, the model 4 showed the best prediction results in the sunshine and solar radiation prediction, and the RMSE of sunshine was 1.5 times and the sunshine RMSE was 3 times less than that of model 1. As a experiment result of solar power generation prediction, the best prediction result was obtained for model 4 as well as sunshine and solar radiation, and the RMSE was reduced by 2.7 times less than that of model 1.

**Key word:** Support vectors machine, Deep learning, Artificial neural network, Sunshine, Solar radiation.

<https://doi.org/10.12673/jant.2018.22.5.478>



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 28 September 2018; Revised 1 October 2018  
Accepted (Publication) 23 October 2018 (30 October 2018)

\*Corresponding Author : Chang-Bok Kim

Tel : +82-10-8908-3946

E-mail : cbkim@gachon.ac.kr

## 1. 서론

신재생 에너지는 화석연료 자원의 고갈과 이산화탄소 배출 규제 그리고 원자력 발전의 위험성 등의 문제로 관심과 수요가 급증하고 있다. 정부는 2030년까지 재생에너지 발전비중을 20%로 확대하고, 95% 이상을 태양광, 풍력 등 청정에너지원으로 신규설비 계획을 수립하였다.

특히 태양광 발전은 타 신재생 에너지 발전원에 비해 자연환경에 영향을 받아 간헐적인 발전원에서 벗어나지 못하고 있는 한계가 있다, 간헐적인 발전량은 설비용량 대비 발전량이 저조하게 되는 원인일 뿐 아니라 발전량의 제어가 어려워 사전에 발전계획을 수립하기 어렵다. 따라서 발전량의 불확실성을 줄이고 신재생 에너지 발전의 경제성 향상을 위하여 높은 정확도의 발전량 예측기술이 필수적이다[1]-[2].

태양광 발전량 예측은 SVM (support vectors machine), 웨이블릿(wavelet), ARIMA, ELM (extreme learning machine), SVR (support vector regression), neuro-fuzzy, 인공신경망 (artificial neural network) 등에 대한 연구가 있었다[3]-[8].

인공지능(artificial intelligence)은 컴퓨터가 인간의 지능적인 행동을 모방할 수 있도록 하는 기계학습의 핵심 분야로서, 최근 인공신경망에 대한 연구가 활발히 진행되고 있다. 인공 신경망은 인간의 뇌 구조를 모방한 기계학습이며, DNN, RNN, LSTM, 강화학습 (reinforcement learning) 등 딥러닝으로 발전하여 영상인식, 음성인식, 자연어 처리, 미래예측 뿐 아니라 인간의 할 수 있는 모든 영역에서 응용되고 있다[9]-[11].

본 연구는 2013년부터 2015년까지의 목표 기상청의 기온, 강수량, 풍향, 풍속, 습도, 운량, 일조, 일사 등 시간별 기상 데이터를 이용하여, 시간별 일조 및 일사 예측을 하였다. 이때, 4가지 모델의 기상요소로 입력력 변수로 하여 비교 분석하였다. 또한, 가장 오차가 적은 모델의 예측된 일조 및 일사 데이터를 이용하여 전라남도 영암 태양광 발전소의 발전량 데이터를 사용하여 발전량을 예측하였다.

예측 알고리즘은 SVM (support vectors machine), 인공신경망 (artificial neural network), DNN (deep neural network)을 사용하였다. 또한, 본 연구는 예측을 위하여 하루 전체인 24시간 데이터, 일몰과 일출 사이의 데이터를 제거한 12시간 데이터, 하루 태양광 발전량의 약 90% 정도인 10시부터 4시까지의 7시간 데이터로 정제하여 데이터를 구축하여 일 데이터로 예측한 결과와 비교 분석하였다.

본 논문은 2장에서 관련연구로서 기상요소와 예측 알고리즘에 대해서 서술하였으며 3장에서 실험을 위한 데이터 구조와 신경망 예측모델을 제안하였다. 또한, 4장에서 실험결과를 비교 검토하였으며, 5장에 결론에 대해서 서술하였다.

## II. 기상요소와 예측 알고리즘

### 2-1 기상요소

태양전지는 태양의 복사에너지에 의해 전기를 생산하기 때문에, 운량과 일사량 그리고 일조량이 매우 중요한 요인이다. 또한, 태양전지가 반도체이기 때문에, 적당한 온도와 습도를 유지해야 한다. 표 1에 2013년에서 2015년까지의 영암 태양광 발전량과 기상요소간의 상관관계를 나타냈다. 기상요소는 목표 기상청의 기상데이터를 이용하였다.

운량은 기본적으로 일조 및 일사량과 상관관계가 높기 때문에 발전량과의 상관관계가 높아야 한다. 그러나 24시간 데이터는 하루 전체의 데이터로서 일몰과 일출 사이에 운량과 상관없이 발전량이 없기 때문에, 상관관계가 -0.251로 매우 낮게 나타난다.

12시간 데이터는 일몰과 일출 사이의 데이터를 삭제하여 상관관계를 나타낸 것으로 기온과 강수량 그리고 전운량의 상관관계가 상승했다. 특히, 전운량의 상관관계는 2배 이상 상승했다. 그러나 일사 및 일조는 소폭 하락했다.

7시간 데이터는 하루 발전량의 약 90%에 달하는 10시부터 4시 사이의 데이터를 이용하여 상관관계를 나타낸 것으로 전운량의 상관관계가 -0.73으로 24시간 데이터의 3배 정도 높아졌음을 알 수 있다.

### 2-2 예측 알고리즘

SVM은 기계학습 분야 중 하나로서, 분류와 회귀 분석을 위해 사용되며, 패턴인식, 자료 분석을 위한 지도학습 모델이다 [12]. SVM은 특징에 따라 서로 유사한 그룹끼리 초평면으로 나누는 것이다. 초평면은 다음과 같다.

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

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

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

표 1. 주요 기상요소와 발전량의 상관관계

Table 1. A correlation between major meteorological factors and power generation.

	24 hour data	12 hour data	7 hour data
Temp.	0.243	0.259	0.182
Precip.	-0.071	-0.118	-0.178
Wind direct.	0.23	0.216	0.191
Wind speed	0.231	0.169	0.111
Humidity	-0.607	-0.595	-0.624
Cloudiness	-0.251	-0.441	-0.73
Sunshine	0.957	0.935	0.877
Solar Rad.	0.851	0.766	0.804

여기서  $W$ 는 초평면의 법선벡터이며,  $x_i$ 는 실수벡터이고,  $y_i$ 는  $x_i$ 가 어떤 클래스에 속해있는지를 나타내는 값으로 1 혹은 -1의 값을 가진다. 인공지능(artificial intelligence)은 컴퓨터가 인간의 지능적인 행동을 모방할 수 있도록 하는 기계학습의 핵심 분야로서, 최근 인공신경망에 대한 연구가 활발히 진행되고 있다. 인공 신경망은 인간의 뇌 구조를 모방한 기계학습이며, DNN, RNN, LSTM, 강화학습(reinforcement learning) 등 딥러닝으로 발전하여 영상인식, 음성인식, 자연어 처리, 미래예측 뿐 아니라 인간의 할 수 있는 모든 영역에서 응용되고 있다.

DNN은 ANN을 심층화하고 ReLu와 tanh 활성화 함수를 사용하여, 심층에 의한 기울기 사라짐, 지역 최솟값 문제를 해결한다. ReLu와 tanh 활성화 함수는 다음과 같이 정의한다.

$$\begin{aligned} \text{actReLU}(x) &= \max(0;x) & (4) \\ \text{acttanh}(x) &= \tanh(x) & (5) \end{aligned}$$

또한, 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. 신경망을 이용한 예측은 오차 역전파(back propagation)를 이용하여 학습을 하므로, 예측에 필요한 입출력 변수의 구성에 따라 정확도가 달라진다.

### III. 제안 예측모델

#### 3-1 데이터 구조

일조 및 일사 예측을 위한 학습 데이터는 2013년에서 2014년까지의 기상 데이터이며, 테스트 데이터는 2015년 기상 데이터이다. 발전량 예측을 위한 학습 데이터는 2015년 1월에서 9월까지의 기상 데이터이며, 테스트 데이터는 10월에서 12월까지의 기상데이터이다. 본 연구는 예측을 위하여 표 1에서 나타난 바와 같이 하루 전체인 24시간 데이터, 일몰과 일출 사이의 데이터를 제거한 12시간 데이터, 하루 태양광 발전량의 약 90% 정도인 10시부터 4시까지의 7시간 데이터로 정제하여 데이터를 구축하여 비교 분석하였다. 기상요소는 데이터의 크기가 모두 다르기 때문에, 데이터의 범위를 일치시켜야 한다. 또한, 인공신경망은 입출력 데이터의 크기가 작아야 학습이 효과적이기 때문에 모든 기상요소를 0과 1사이로 정규화를 하였다.

$$\tilde{d}_i = \frac{d_i - \min\{d\}}{\max\{d\} - \min\{d\}} \quad (6)$$

$d_i$ 는 기상요소이며,  $\min\{1:d\}$ 은 기상요소 중 가장 작은 값 그리고  $\max\{1:d\}$ 은 기상요소 중 가장 큰 값을 나타낸다.

표 2. 일조 및 일사 예측을 위한 데이터 구조

Table 2. Data structure for sunshine and solar radiation forecasting.

model	data structure
model 1	A, B, C, D, E, F
model 2	A, B, C, D, E, F, G0, H0
model 3	A, B, C, D, E, F, G0-G1, H0-H1
model 4	A, B, C, D, E, F, G0-G2, H0-H2

표 3. 태양광 발전량 예측을 위한 데이터 구조

Table 3. Data structure for solar power generation.

model	data structure
model 1	A, B, C, D, E, F
model 2	A, B, C, D, E, F, G'0-G'2
model 3	A, B, C, D, E, F, H'0-H'2
model 4	A, B, C, D, E, F, G'0-G'2, H'0-H'2

기상요소는 기온(A), 강수량(B), 풍향(C), 풍속(D), 습도(E), 운량(F), 일조(G), 일사(H)이다. 이때, 본 연구는 일조 및 일사 예측을 위해 4개의 모델로 데이터를 구축하였다. 표 2에 일조 및 일사 예측을 위한 데이터 구조를 나타냈다. 여기서 숫자는 시간을 의미하며, 0은 현재시각, 1은 1시간 전, 2는 2시간 전을 의미한다. 모델 1은 일조 일사를 제외한 기상 데이터로 구축한 것이며, 모델 2는 현재시각의 일조와 일사 데이터로 구축한 것이다. 모델 3은 현재시각, 1시간 전 일조와 일사 데이터로 구축한 것이며, 모델 4는 현재시각부터 2시간 전 일조와 일사 데이터로 구축한 것이다.

표 3에 발전량 예측을 위한 데이터 구조를 나타냈다. 발전량 예측을 위한 데이터 구조는 일조 및 일사 데이터구조와 동일하다. 그러나 여기서 일조 및 일사데이터는 가장 좋은 예측결과를 사용하였다. 이것은 각각의 기상요소 중에서 태양광 발전예측에 보다 많은 영향을 끼치는 기상요소를 찾기 위함이다.

#### 3-2 예측 입출력모델

본 연구에서 사용하는 SVM, ANN, DNN와 같은 지도학습 알고리즘은 출력변수일 라벨과 상관관계가 높은 입력변수를 설정해야 높은 정확률을 얻을 수 있다. 지도학습의 입출력 모델은 예측에서 가장 중요한 요소이지만 인간이 직접 결정해야하기 때문에, 반복적인 실험에 의해 결정해야 한다.

표 4에 일조 및 일사 예측을 위한 입출력 구조에 대해서 나타났다. 표에서 숫자는 시간을 의미하며, 현재시간 0을 기준으로 한다. 표 4는 일반적인 예측 입출력 구조로서 입출력 모델 1은 현재 시간의 기본적인 기상요소인 기온(A), 강수량(B), 풍향(C), 풍속(D), 습도(E), 운량(F) 등을 이용하여 1시간 후의 일사 및 일조 예측을 위한 입출력 모델이다. 또한, 모델 2는 모델 1에 현재시각의 일조 및 일사 요소를 추가한 것이며, 모델 3은 모델

2에 1시간 전의 일조 및 일사 요소를 추가한 것이다. 또한 모델 4는 모델 3에 2시간 전의 일조 및 일사 요소를 추가한 것이다. 출력변수인 라벨은 1시간 후의 일사 및 일조 데이터이다.

표 6에 태양광 발전을 위한 입출력 모델에 대해서 나타냈다. 모델 1은 기상요소만을 이용한 발전량 예측이며, 모델 2는 예측된 일조 데이터로 발전량을 예측한 것이다. 또한 모델 3은 예측된 일사 데이터로 발전량을 예측한 것이며, 모델 4는 예측된 일사 및 일조 데이터로 발전량을 예측한 것이다. 표 7에 본 실험에 사용된 파라미터에 대해서 나타냈다.

ANN의 입출력 노드 수는 각 입출력 모델의 입력변수와 라벨과 동일하며, 중간층의 노드 수는 5개로 하였다. 또한, 활성화 함수는 시그모이드를 이용하였으며, 학습률을 0,01로 하여 15000번 반복 학습하였다.

DNN은 ANN과 마찬가지로 입출력 노드 수는 각 입출력 모델의 입력변수와 라벨과 동일하며, 중간층의 노드 수는 32개로

표 4. 일조 및 일사 예측을 위한 입출력 구조

Table 4. Input output structure for sunshine and solar radiation forecasting.

model	Input variable							label
	A-F	G2	G1	G0	H2	H1	H0	
model 1	0	/	/	/	/	/	/	1
model 2	0	/	/	0	/	/	0	1
model 3	0	/	-1	0	/	-1	0	1
model 4	0	-2	-1	0	-2	-1	0	1

표 5. 태양광 발전량 예측을 위한 입출력 구조

Table 5. Input output structure for solar power generation.

model	Input variable							label
	A-F	G2	G1	G0	H2	H1	H0	
model 1	0	/	/	/	/	/	/	1
model 2	0	-2	-1	0	/	/	/	1
model 3	0	/	/	/	-2	-1	0	1
model 4	0	-2	-1	0	-2	-1	0	1

표 6. 신경망 파라미터

Table 6. Neural network parameters.

parameters	algorithm	
	ANN	DNN
Number of input layer nodes	Number of input variables in model	Number of input variables in model
Number of hidden layer nodes	5	32
Number of hidden layer	1	3
Number of output layer node	1	1
Activation function	Sigmoid	ReLU
Learning rate	0.01	0.01
Number of iterations	15000	15000

하여 3층으로 구성하였다. 또한, 활성화 함수는 ReLu와 tanh 활성화 함수를 사용하였으며, 학습률을 0,01로 하여 15000번 반복 학습하였다.

#### IV. 실험 및 검토

실험환경은 Window 10 기반으로 파이썬(Python) 3.6기반 텐서플로우(Tensorflow) GPU Version을 이용하였다.

일조 및 일사 예측을 위한 학습 데이터는 2013년에서 2014년까지의 기상 데이터로서, 17520개의 레코드로 구성되어 있으며, 테스트 데이터는 2015년 기상 데이터로서 8760 개의 레코드로 구성되어 있다. 또한 태양광 발전량 예측을 위한 학습데이터는 2015년도 1월부터 9월까지의 데이터이며, 테스트 데이터는 10월부터 12월까지의 데이터이다. 예측 정확성과 예측 결과 평가를 위해서 다음과 같이 평균 제곱근오차(Root Mean Square Error), 평균절대오차(Mean Absolute Error), BIAS, 상관관계를 사용하였다. 만약 RMSE >> MAE라면 예측된 값은 실제 값과 높은 편차를 가지며, 비슷한 값을 가지면 예측된 값과 실제 값이 낮은 편차를 가진다는 것을 의미 한다. BIAS는 예측된 값과 실제 값이 더 높거나 낮은 값을 예측하는지 여부를 평가할 수 있다. 상관관계는 예측된 값은 실제 값의 유사성을 평가하기 위한 측정이다.

$$RMSE(x',x) = \frac{1}{N} \sqrt{\sum_{n=1}^N (x'_n - x_n)^2} \quad (7)$$

$$MAE(x',x) = \frac{1}{N} \sum_{n=1}^N |x'_n - x_n| \quad (8)$$

$$BIAS(x',x) = \frac{1}{N} \sum_{n=1}^N (x'_n - x_n) \quad (9)$$

$$COR.(x',x) = \frac{\sum_{n=1}^N (x'_n - \bar{x}') \times \sum_{n=1}^N (x_n - \bar{x})}{\sqrt{\sum_{n=1}^N (x'_n - \bar{x}')^2 \times \sum_{n=1}^N (x_n - \bar{x})^2}} \quad (10)$$

여기서 x'은 예측값이며, x는 실제값이다. 표 7에 일조 및 일사량 예측 결과에 대해서 나타냈다. 모든 실험은 5회 반복하여 평균값을 계산한 것이다. 표에서 회색 부분이 각 모델에서 가장 좋은 결과가 나온 것이다. 일조 예측결과 모델 1은 DNN3이 RMSE가 0.245, MAE가 0.159, 상관관계가 0.790로 예측결과가 가장 좋았으며, 모델 2는 DNN1이 RMSE가 0.150, MAE가 0.080, 상관관계가 0.928로 예측결과가 가장 좋았다. 또한, 모델 3은 DNN1이 RMSE가 0.132, MAE가 0.066, 상관관계가 0.942로 예측결과가 가장 좋았으며, 모델 4는 DNN1이 RMSE가 0.129, MAE가 0.065, 상관관계가 0.944로 예측결과가 가장 좋았다.

표 7. 일조량 및 일사량 예측결과

Table 7. A forecasting result of sunshine and solar radiation.

		A forecasting result of sunshine					A forecasting result of solar radiation				
		SVM	ANN	DNN1	DNN2	DNN3	SVM	ANN	DNN1	DNN2	DNN3
model 1	RMSE	0.324	0.313	0.303	0.284	0.245	0.178	0.180	0.179	0.193	0.159
	MAE	0.251	0.227	0.210	0.200	0.159	0.123	0.130	0.134	0.151	0.124
	COR.	0.565	0.613	0.640	0.727	0.790	0.608	0.634	0.635	0.608	0.734
	BIAS	0.005	0.007	0.018	-0.005	-0.019	0.016	-0.038	0.039	0.031	0.021
model 2	RMSE	0.189	0.182	0.150	0.197	0.233	0.074	0.070	0.071	0.094	0.112
	MAE	0.091	0.106	0.080	0.117	0.153	0.045	0.043	0.047	0.068	0.085
	COR.	0.880	0.886	0.928	0.883	0.811	0.942	0.946	0.949	0.925	0.874
	BIAS	0.007	0.018	-0.025	-0.030	-0.016	0.013	0.007	0.012	-0.02	-0.011
model 3	RMSE	0.182	0.174	0.132	0.179	0.232	0.060	0.058	0.056	0.071	0.106
	MAE	0.092	0.101	0.066	0.105	0.147	0.037	0.032	0.033	0.048	0.077
	COR.	0.887	0.897	0.942	0.901	0.814	0.962	0.964	0.971	0.954	0.888
	BIAS	-0.002	0.009	-0.019	-0.008	-0.016	-0.005	0.001	-0.007	0.001	-0.002
model 4	RMSE	0.181	0.172	0.129	0.177	0.234	0.057	0.056	0.053	0.071	0.107
	MAE	0.092	0.101	0.065	0.106	0.148	0.036	0.031	0.029	0.048	0.079
	COR.	0.888	0.899	0.944	0.903	0.812	0.965	0.967	0.973	0.956	0.887
	BIAS	-0.002	0.008	-0.015	0.005	-0.019	-0.006	0.002	-0.001	0.004	0.001

실험결과 모델 4가 가장 예측결과가 좋았으며, 모델 1 보다 RMSE가 1.9배 정도 좋아 졌음을 알 수 있다.

일사 예측 결과 모델 1은 DNN3이 RMSE가 0.159, MAE가 0.124, 상관관계가 0.734로 예측결과가 가장 좋았으며, 모델 2는 ANN1이 RMSE가 0.70, MAE가 0.043, 상관관계가 0.946으로 예측결과가 가장 좋았다. 또한, 모델 3은 DNN1이 RMSE가 0.056, MAE가 0.033, 상관관계가 0.971로 예측결과가 가장 좋았으며, 모델 4는 DNN1이 RMSE가 0.053, MAE가 0.029, 상관관계가 0.973로 예측결과가 가장 좋았다. 실험결과 모델 4가 가장 예측결과가 좋았으며, 모델 1보다 RMSE가 3배 정도 좋아 졌음을 알 수 있다. 결과적으로 일사 및 일조 예측결과 모델 4의 예측결과가 가장 좋았다.

일사 예측결과가 일조 예측결과보다 두 배 이상 좋았으며, 예상과는 달리 DNN1이 DNN2와 DNN3 보다 예측 결과가 좋았다. 그림 1에서 4까지는 모델 2와 모델 4에서 가장 오차가 적은 일조 및 일사 결과를 나타냈다. 일조는 2015년 3월 19일부터 20시부터 3월 24일 19시, 일조는 2015년 1월 8일 11시부터 1월 13일 10시까지의 그래프이다.




그림 1. 모델 2의 일조량 예측 결과  
Fig. 1. A forecasting result of sunshine in model 2.




그림 2. 모델 4의 일조량 예측 결과  
Fig. 2. A forecasting result of sunshine in model 4.




그림 3. 모델 2의 일사량 예측결과  
Fig. 3. A forecasting result of solar radiation in model 2.




그림 4. 모델 4의 일사량 예측결과  
Fig. 4. A forecasting result of solar radiation in model 4.

본 연구는 발전량 예측을 위하여 4개의 모델을 구성하여 실험하였다. 모델 1은 기상요소만을 사용한 발전량 예측이며, 모델 2는 기상요소와 예측된 일조 데이터를 사용한 발전량 예측이다. 또한, 모델 3은 기상요소와 예측된 일사 데이터를 이용한 예측이며, 모델 4는 기상요소와 예측된 일조 및 일사 데이터를 이용한 예측이다.

표 8에 발전량 예측결과에 대해서 나타냈다. 표에서 회색 부분이 각 모델에서 가장 좋은 결과가 나온 것이다. 실험결과 기상예보를 사용한 입출력 모델 4의 발전량 결과가 좋았음을 알 수 있다, 모델 1은 SVM이 RMSE가 0.199, MAE가 0.131, 상관관계가 0.589으로 예측결과가 가장 좋았으며, 모델 2는 DNN1이 RMSE가 0.117, MAE가 0.066, 상관관계가 0.862으로 예측결과가 가장 좋았다. 또한, 모델 3은 DNN1이 RMSE가 0.083, MAE가 0.046, 상관관계가 0.929로 예측결과가 가장 좋았으며, 모델 4는 DNN1이 RMSE가 0.080, MAE가 0.047, 상관관계가 0.931으로 예측결과가 가장 좋았다. 실험결과 모델 4가 가장 예측결과가 좋았으며, 모델 1보다 RMSE가 2.6배 정도 좋아 졌음을 알 수 있다.

그림 5와 6에 2015년 10월 21일부터 18시부터 10월 24일 06 시까지의 발전량 그래프에 대해서 나타냈다.

표 8. 발전량 예측결과

Table 8. A result forecast of solar power generation.

		SVM	DNN1	DNN2	DNN3
model 1	RMSE	0.199	0.204	0.237	0.221
	MAE	0.131	0.150	0.189	0.176
	COR.	0.589	0.557	0.587	0.725
	BIAS	-0.059	0.008	0.116	0.134
model 2	RMSE	0.121	0.117	0.154	0.216
	MAE	0.067	0.066	0.113	0.176
	COR.	0.841	0.862	0.823	0.739
	BIAS	-0.025	0.002	0.060	0.129
model 3	RMSE	0.085	0.083	0.118	0.207
	MAE	0.055	0.046	0.086	0.161
	COR.	0.915	0.929	0.898	0.771
	BIAS	-0.007	0.021	0.048	-0.129
model 4	RMSE	0.081	0.080	0.112	0.197
	MAE	0.050	0.047	0.080	0.153
	COR.	0.924	0.931	0.901	0.776
	BIAS	-0.012	0.021	0.036	0.114




그림 5. 모델 2의 태양광 발전 예측

Fig. 5. A forecasting result of solar power generation in model 2.




그림 6. 모델 4의 태양광 발전 예측

Fig. 6. A forecasting result of solar power generation in model 4.

## V. 결론 및 향후 과제

본 연구는 시간별 기상 데이터를 이용하여, 태양광 발전 예측을 하였다. 본 연구는 4가지 패턴의 입출력 모델로 일조 및 일사 예측을 하였다. 또한, 예측된 일조 및 일사 데이터와 실제 발전량 데이터를 이용하여 발전량을 예측하였다. 실험결과 모델 4가 가장 예측결과가 우수했으며, 모델 1에 비해 일조는 RMSE가 1.5배 정도 그리고 일사는 3배 정도 오차가 줄었다. 일사 예측결과가 일조 예측결과보다 두 배 이상 좋았다. 또한 예상과는 달리 DNN1이 DNN2와 DNN3 보다 예측 결과가 좋았다. 이것은 전운량의 상관관계는 좋았으나 일조 및 일사의 상관관계가 낮아짐에 기인한 것으로 예상된다. 태양광 발전예측은 가장 우수한 예측 일사 및 일조 데이터를 이용하여 예측하였다. 실험결과 일조 및 일사와 마찬가지로 기상예보를 사용한 입출력 구조의 모델 4가 가장 예측결과가 좋았으며, 모델 1 보다 RMSE가 2.7배 정도 좋았다. 향후 기상예보에 적합한 입출력 모델과 시계열에 적합한 딥러닝 네트워크 구조를 이용한 학습을 통해 보다 향상된 예측에 대한 연구가 필요하다.

## Acknowledgments

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가

원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20174030201470)

### References

[1] 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, May. 2017

[2] S. B. Rhee, K. H. Kim, and S. G. Lee, "Optimal operation scheme of microgrid system based on renewable energy resources," *The Transactions of the Korean Institute of Electrical Engineers*, Vol. 60, No. 8, pp. 1467-1472, Aug. 2011

[3] A. J. Conejo, M. a. Plazas, R. Espínola, S. Member, and A. B. Molina, "Day ahead electricity price forecasting using the wavelet transform and ARIMA models," *IEEE Transactions On Power Systems*, Vol. 20, No. 2, pp. 1035-1042, 2005.

[4] 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.

[5] 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.

[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] 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.

[8] 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*, Vol. 4, No. 6A, pp. 32-38, Apr.2013

[9] Y. Bengio, "Learning deep architectures for AI," *Foundations and Trends in Machine Learning.*, Vol. 2, No. 1, pp. 1-127, Jan. 2009.

[10] L. Deng and D. Yu, "Deep learning: methods and applications," *Foundations and Trends in Signal Processing*, Vol. 7, No. 3-4, pp. 197-387, 2014.

[11] Y. LeCun, Y. Bengio, and G. Hinton. "Deep learning," *Nature*, Vol 521.7553, pp. 436-444, 2015

[12] 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.

#### 장 진 혁 (Jin-Hyuk Jang)



2014년 2월 ~ 현재 : 가천대학교 에너지IT학과 (공학사)  
관심분야 : 딥러닝, 빅 데이터, IOT

#### 신 동 하 (Dong-Ha Shin)



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

#### 김 창 복 (Chang-Bok Kim)



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