

RNN-LSTM을 이용한 태양광 발전량 단기 예측 모델

Short Term Forecast Model for Solar Power Generation using RNN-LSTM

신 동 하 · 김 창 복*

가천대학교 에너지 IT학과

Dong-Ha Shin · Chang-Bok Kim*

Department of Energy IT, Gachon University, Gyeonggi-do, 13120, Korea

[요 약]

태양광 발전은 기상 상태에 따라 간헐적이기 때문에 태양광 발전의 효율과 경제성 향상을 위해 정확한 발전량 예측이 요구된다. 본 연구는 목포 기상대에서 예보하는 기상 데이터와 영암 태양광 발전소의 발전량 데이터를 이용하여 태양광 발전량 단기 딥러닝 예측모델을 제안하였다. 기상청은 기온, 강수량, 풍향, 풍속, 습도, 운량 등의 기상요소를 3일간 예보한다. 그러나 태양광 발전량 예측에 가장 중요한 기상요소인 일조 및 일사 일사량 예보하지 않는다. 제안 모델은 예보 기상요소를 이용하여, 일조 및 일사 일사량을 예측 하였다. 또한 발전량은 기상요소에 예측된 일조 및 일사 기상요소를 추가하여 예측하였다. 제안 모델의 발전량 예측 결과 DNN의 평균 RMSE와 MAE는 0.177과 0.095이며, RNN은 0.116과 0.067이다. 또한, LSTM은 가장 좋은 결과인 0.100과 0.054이다. 향후 본 연구는 다양한 입력요소의 결합으로 보다 향상된 예측결과를 도출할 수 있을 것으로 기대된다.

[Abstract]

Since solar power generation is intermittent depending on weather conditions, it is necessary to predict the accurate generation amount of solar power to improve the efficiency and economical efficiency of solar power generation. This study proposes a short - term deep learning prediction model of solar power generation using meteorological data from Mokpo meteorological agency and generation data of Yeongam solar power plant. The meteorological agency forecasts weather factors such as temperature, precipitation, wind direction, wind speed, humidity, and cloudiness for three days. However, sunshine and solar radiation, the most important meteorological factors for forecasting solar power generation, are not predicted. The proposed model predicts solar radiation and solar radiation using forecast meteorological factors. The power generation was also forecasted by adding the forecasted solar and solar factors to the meteorological factors. The forecasted power generation of the proposed model is that the average RMSE and MAE of DNN are 0.177 and 0.095, and RNN is 0.116 and 0.067. Also, LSTM is the best result of 0.100 and 0.054. It is expected that this study will lead to better prediction results by combining various input.

Key word : Solar power generation forecasting, Deep learning, Artificial neural network, Sunshine, Solar radiation.

<https://doi.org/10.12673/jant.2018.22.3.233>



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 23 April 2018; Revised 4 June 2018

Accepted (Publication) 19 June 2018 (30 June 2018)

*Corresponding Author : Chang-Bok Kim

Tel : +82-10-8908-3946

E-mail : cbkim@gachon.ac.kr

I. 서론

최근 화석 연료자원의 고갈과 이산화탄소 배출 규제 그리고 자연재해에 의한 원자력 발전의 위험성 등의 문제로 태양광 발전에 대한 관심과 수요가 급증하고 있다. 태양광 발전은 소규모 발전에 적용하기 시작하여, 최근에는 대규모 발전소를 구축하여 전력회사에 판매하거나 도시에 전력수요를 공급하고 있다. 섬이나 내륙 오지 등 전기 공급이 어려운 곳에서는 태양광, 풍력, 조력 발전 등 신재생 에너지를 통해 에너지 자립을 위한 마이크로그리드(microgrid)에 대한 연구가 진행 중에 있다[1]-[3].

태양광 발전은 에너지원이 무한하고 청정하며, 유지보수가 용이하고, 수명이 길다는 장점이 있다. 그러나 초기투자비와 발전단가가 높고, 설치장소가 한정적이며, 에너지 밀도가 낮아 큰 설치면적이 필요하다는 단점이 있다[4]. 특히, 기상상태에 의존하기 때문에 발전량이 매우 간헐적이며 발전량의 조정이 어려워 사전에 발전계획을 수립하기 어렵다. 따라서 태양광 발전량의 불확실성을 줄이고 태양광 발전의 경제성을 향상시키기 위하여 높은 정확도의 태양광 발전량 예측이 필수적이다. 발전량 예측은 장단기 예측이 있다. 장기예측은 태양광 발전소의 초기 투자비용이 많이 발생하기 때문에, 발전수익 예측과 투자계획을 위해 이용된다. 단기예측은 태양광 발전소의 효율적인 운영과 다른 전력계통과 안정적인 연계에 이용할 수 있다. 단기예측은 실시간으로 발전량을 예측하는 초단기 예측[5]-[6], 다음날인 24시간 앞의 발전량을 예측하는 연구 등이 있다[7]. 태양광 발전예측은 ELM (extreme learning machine), SVR (support vector regression), neuro-fuzzy, 신경망 등에 대한 연구가 있다 [8]-[12].

본 연구는 2013년부터 2015년까지의 기상청에서 예보하는 시간별 기상 데이터와 영암 태양광 발전소의 시간별 발전량 데이터를 이용하여, 단기 예측모델을 제안하였다. 기상 데이터는 영암 발전소 근처의 목포 기상청에서 예보하는 기온, 강수량, 풍향, 풍속, 습도, 운량 등의 기상요소를 이용하였다. 기상청에서는 태양광 발전에 가장 중요한 기상요소인 일조 및 일사량을 예보하지 않기 때문에, 예보되는 기상요소를 이용하여 일조 및 일사량을 예측하였다. 또한, 예측된 일사 및 일조량을 이용하여 태양광 발전량을 예측하였다. 예측을 위한 기계학습은 DNN (deep neural network), RNN (recurrent neural network), LSTM (long short term memory) 등 딥러닝 네트워크를 구글의 텐서플로우(tensorflow)로 구축하여 예측율을 비교 분석하였다.

II. 예측 요소

태양광 발전 예측요소는 기상요소, 지리요소, 설비요소 등이 있다. 태양전지는 태양의 복사에너지에 의해 전기를 생산하기 때문에, 운량과 일사량 그리고 일조량이 매우 중요한 요인이다.

표 1. 일조 및 일사량과 발전량의 상관관계

Table 1. A correlation between sunshine and solar radiation and power generation.

Item	2013	2014	2015	Average
Sunshine	0.8515	0.8526	0.8477	0.85
Solar Rad.	0.959	0.957	0.9575	0.96

또한, 태양전지가 반도체이기 때문에, 적당한 온도를 유지해야 한다. 따라서 대부분의 기상요소는 태양광 발전에 가장 많은 영향을 주는 요소이다. 지리요소는 태양의 고도에 관계가 있는 위도, 경도 및 해발높이 등이 있다. 설비요소는 고정형, 고정가변형, 추적형 등 태양광 패널의 움직임 여부와 축전지 및 전력변환장치의 효율 등이 있다. 본 연구는 기존 영암 발전소의 시간별 태양광 발전 데이터를 사용하였기 때문에, 지리요소와 설비요소를 제외한 기상요소만을 이용한 발전량 예측을 하였다. 기상청은 기온, 강수량, 풍향, 풍속, 습도, 운량 등을 3일간 예보한다. 그러나 태양광 발전예측에 가장 상관관계가 높은 일조 및 일사량은 예보하지 않는다. 따라서 정확한 태양광 발전예측을 위해 예보된 기상요소를 기반으로 정확한 일조 및 일사량을 예측해야 한다. 표 1에 2013년에서 2015년까지의 일조 및 일사량과 영암 태양광 발전량의 상관관계를 나타냈다.

일조 및 일사량과 가장 관계가 있는 과거 운량 데이터는 실측 데이터로서 등 맑음에서 흐림까지 11단계이다. 그러나 운량의 예보는 맑음(0≤운량≤2), 구름 조금(3≤운량≤5), 구름 많음(6≤운량≤8), 흐림(9≤운량≤10) 등 4 단계이다. 따라서 운량 예보를 시간별 데이터로 사용하기 위해 다음과 같은 선형 보간법으로 데이터를 구축하였다.

$$f(x) = f(x_0) + \frac{x - x_0}{x_1 - x_0} \times (f(x_1) - f(x_0)) \quad (1)$$

태양광 발전예측을 위한 모든 기상요소 데이터는 크기가 모두 다르기 때문에, 데이터의 범위를 일치시키거나 분포를 유사하게 만들어야 한다. 또한, 인공지능은 입력 데이터의 크기가 작아야 학습이 효과적이기 때문에, 모든 독립변수인 입력 데이터를 다음과 같이 min-max 정규화를 사용하여 정규화 하였다.

$$\tilde{d}_i = \frac{d_i - \min(1:d)}{\max(1:d) - \min(1:d)} \quad (2)$$

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

딥러닝은 인간의 뇌 구조를 모방한 기계학습으로 DNN, RNN, LSTM 등이 있다. DNN은 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 방

지를 위해 중간층 노드를 강제로 없애는 드롭아웃(drop out) 방식을 이용하여 중간층을 깊게 한 심층 신경망이다.

RNN은 하나의 입출력 패턴을 가진 DNN 병렬 체인 구조로 연결한 형태로, 과거 학습결과를 현재 학습에 사용하는 딥러닝 네트워크로서, 시계열 데이터를 처리하는데 효과적이다. RNN은 하나의 tanh 혹은 ReLu 활성화함수를 가진 구조로서, 체인이 길어지면 과거의 학습 결과가 사라지는 장기 의존성문제가 있다. LSTM은 전체 체인을 관통하는 셀 스테이트(cell state)를 통해 과거 학습결과를 큰 변함없이 전달하는 구조로 장기 의존성 문제를 해결한다. LSTM은 첫번째 단계로 sigmoid 함수를 이용해 삭제할 정보를 결정하고, 두 번째 단계로 또 다른 sigmoid 함수와 tanh 함수를 이용해 새로운 정보가 셀 스테이트에 저장될지 결정한다. 세 번째 단계는 셀 스테이트를 업데이트하고 마지막으로 마지막 sigmoid 함수와 셀 스테이트에서 나온 출력을 통과시킨 마지막 tanh 함수로 어떤 출력 값을 출력할지를 결정한다[13]-[14].

III. 예측 모델

기상청에서는 태양광 발전에 가장 중요한 기상요소인 일조 및 일사량을 예보하지 않기 때문에, 제안 예측모델은 예보되는 기상요소만을 이용하여, 일조 및 일사량을 예측하였다. 또한, 예측된 일사 및 일조량을 이용하여 태양광 발전량을 예측하였다. 그림 1에 제안 예측모델에 대해서 나타냈다.

예측모델은 일조량과 일사량 예측을 위해 기온(E1), 강수량(E2), 풍향(E3), 풍속(E4), 습도(E5), 운량(E6) 등을 입력으로 하였으며, 출력은 현재시각과 1시간, 2시간, 24시간 후의 일조(Y1) 또는 일사(Y2)로 하여 일조 및 일사량을 예측하였다. 여기서 현재시각 예측은 예보되는 기상요소를 이용하여, 예보되지 않는 일조 및 일사량을 예측하기 위함이다. 또한, 발전량 예측을 위해 E1 - E6의 기상요소와 일사량 예측모델을 통해 예측된 일사량(Y1), 일조량(Y2)을 입력으로 하였으며, 출력은 현재시각과 1시간, 2시간, 24시간 후의 태양광 발전량(Y3)으로 하여 발전량을 예측하였다. 본 연구는 DNN, RNN, LSTM 등 딥러닝 네트워크를 구글의 텐서플로우로 구축하여 예측율을 비교 분석하였다.




그림 1. 일조 및 일사량을 추출하기 위한 예측모델
 Fig. 1. A forecasting model for extracting sunshine and solar radiation.




그림 2. DNN 일조 및 일사 예측모델
 Fig. 2. A forecasting model of DNN sunshine and solar radiation.

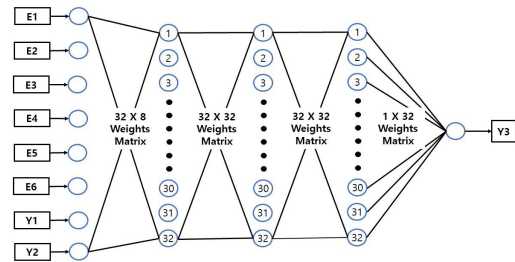


그림 3. DNN 태양광 발전 예측모델
 Fig. 3. A forecasting model of DNN solar power generation.

그림 2에 DNN의 일조 및 일사 예측모델을 나타냈다. 일조 및 일사 예측모델의 입력 층은 6노드, 중간층은 32 노드로 하여 3층으로 설정하였으며, 출력 층은 1 노드로서 현재시각과 1시간, 2시간, 3시간, 24시간 후의 일조량 혹은 일사량이다.

그림 3에 DNN을 이용한 태양광 발전 예측모델에 대해서 나타냈다. 발전량 예측모델의 입력 층은 예보되는 기상요소와 예측된 일사, 일조량이 추가되어 총 노드 수가 8노드이다. 출력 층은 현재시각과 1시간, 2시간, 3시간 그리고 하루 뒤인 24시간 후의 발전량이다. 그림 4에 RNN-LSTM을 이용한 일사 및 일조 예측 입출력 모델에 대해서 나타냈다.

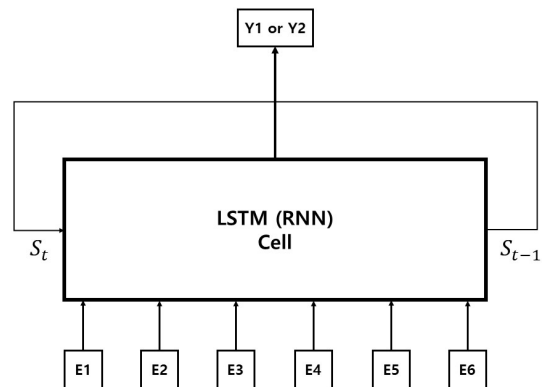


그림 4. RNN-LSTM 일조 및 일사 예측모델
 Fig. 4. A forecasting model of RNN-LSTM sunshine and radiation.

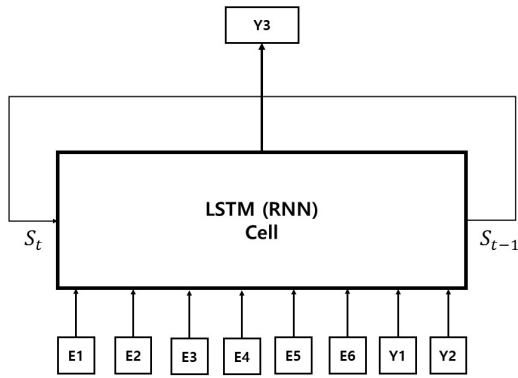


그림 5. RNN-LSTM 태양광 발전량 예측모델
Fig. 5. A forecasting model of RNN-LSTM solar power generation.

RNN-LSTM은 기상 및 전력데이터가 하루 간격으로 유사한 패턴을 갖기 때문에, 하루 단위로 학습하기 위해 타임스텝을 24개로 하여, RNN-LSTM셀로 구성하였다. 또한 각 셀은 6개의 기상 데이터를 입력하였다. 이때 각 셀의 출력은 중간층으로 연결되며, 중간층의 노드는 32개로 하였다. 최종적으로 출력 층은 출력 라벨로서 현재시각과 1시간, 2시간 그리고 24시간 후의 일조량 혹은 일사량이다. 그림 5에 RNN-LSTM을 이용한 발전량 예측모델에 대해서 나타냈다. RNN-LSTM 발전량 예측모델은 예측된 일사 및 일조량이 입력에 추가되어 총 8개의 입력을 갖는다. 출력은 현재시각과 1시간, 2시간, 3시간 그리고 하루 뒤인 24시간 후의 발전량이다.

IV. 실험결과

본 연구의 실험환경은 window 10 기반 파이썬(python) 3.6 그리고 텐서플로우 GPU 버전을 이용하였다. 일조 및 일사 예측을 위한 학습 데이터는 2013년 1월에서 2015년 9월까지의 기상 데이터이며, 테스트 데이터는 2015년 10월에서 12월까지의 기상 데이터이다. 또한, 발전량 예측을 위한 학습 데이터는 2015년 10월에서 11월까지의 기상데이터와 예측된 일사량, 일조량 그리고 발전량 데이터이며, 테스트 데이터는 2015년 12월의 기상데이터와 예측된 일사량, 일조량 그리고 발전량 데이터이다. 실험은 학습 데이터를 사용하여 DNN을 15000번, RNN과 LSTM을 5000번 학습하여 모델을 생성하고, 테스트 데이터로 모델을 평가하였다. 각 예측에 대한 정확성은 평균 제곱근 오차와 평균절대오차를 사용하였다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (actual_i - predict_i)^2} \tag{3}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |predict_i - actual_i| \tag{4}$$

표 2. 일조 예측결과

Table 2. A forecasting result of Sunshine.

Time		DNN	RNN	LSTM
Current time	RMSE	0.277	0.147	0.145
	MAE	0.189	0.087	0.081
After 1 hour	RMSE	0.305	0.191	0.181
	MAE	0.225	0.125	0.097
After 2 hours	RMSE	0.332	0.216	0.215
	MAE	0.262	0.127	0.119
After 24 hours	RMSE	0.348	0.284	0.279
	MAE	0.281	0.198	0.197

표 2에 DNN, RNN, LSTM을 이용한 일조 예측 결과에 대해서 나타냈다. 가장 좋은 예측 결과는 현재시각 예측으로 DNN의 평균 RMSE와 MAE는 0.277과 0.189이며, RNN은 0.147과 0.087이다. 또한, LSTM은 0.145와 0.081이다.




그림 6. DNN 현재시각 일조 예측결과
Fig. 6. A forecasting result of DNN current time sunshine.




그림 7. RNN 현재시각 일조 예측결과
Fig. 7. A forecasting result of RNN current time sunshine.




그림 8. LSTM 현재시각 일조 예측결과
 Fig. 8. A forecasting result of LSTM current time sunshine.




그림 10. RNN 현재시각 일사 예측결과
 Fig. 10. A forecasting result of RNN current time solar radiation.

표 3. 일사 예측결과

Table 3. A forecasting result of Solar radiation.

Time		DNN	RNN	LSTM
Current time	RMSE	0.146	0.091	0.078
	MAE	0.100	0.057	0.048
After 1hour	RMSE	0.155	0.116	0.089
	MAE	0.116	0.082	0.056
After 2hours	RMSE	0.164	0.104	0.103
	MAE	0.131	0.066	0.063
After 24hours	RMSE	0.161	0.136	0.124
	MAE	0.123	0.097	0.075

표 3에 DNN, RNN, LSTM을 이용한 일사 예측 결과에 대해서 나타냈다. 가장 좋은 예측 결과는 현재 시각 예측으로 DNN의 평균 RMSE와 MAE는 0.146과 0.1이며, RNN은 0.0918과 0.057이다. 또한, LSTM은 0.078011과 0.047877이다. 실험결과 DNN, RNN, LSTM 순으로 예측 결과가 좋아지는 것을 확인할 수 있다. 그림 9, 그림 10, 그림 11에 DNN, RNN, LSTM의 현재 시각의 일사 예측 결과를 그래프로 나타내었다.




그림 9. DNN 현재시각 일사 예측
 Fig. 9. A forecasting result of DNN current time solar radiation.




그림 11. LSTM 현재시각 일사 예측결과
 Fig. 11. A forecasting result of LSTM current time solar radiation.

표 4에 DNN, RNN, LSTM을 이용한 발전량 예측 결과에 대해서 나타냈다. 가장 좋은 예측 결과는 현재시각 예측으로 DNN의 평균 RMSE와 MAE는 0.177과 0.095395이며, RNN은 0.116과 0.066591이다. 또한, LSTM은 0.100과 0.054이다. 실험 결과 역시 LSTM의 결과가 가장 좋은 것을 확인할 수 있다. 하지만 24시간 후 예측에서 RNN이 LSTM보다 RMSE는 높지만 MAE는 낮은 수치를 보여준다. 그림 12, 그림 13에 RNN과 LSTM의 일주일간 현재시각 예측 결과를 나타내었고, 그림 14, 그림 15에 일주일간 24시간 후 발전량 예측의 결과를 그래프로 나타내었다.

표 4. 발전량 예측결과

Table 4. A forecasting result of solar power generation.

Time		DNN	RNN	LSTM
Current time	RMSE	0.177	0.116	0.100
	MAE	0.095	0.067	0.054
After 1hour	RMSE	0.189	0.128	0.119
	MAE	0.103	0.073	0.065
After 2hours	RMSE	0.196	0.140	0.136
	MAE	0.116	0.082	0.07
After 24hours	RMSE	0.208	0.182	0.174
	MAE	0.133	0.105	0.107




그림 12. RNN 현재시각 발전량 예측결과
 Fig. 12. A forecasting result of RNN current time solar power generation.




그림 13. LSTM 현재시각 발전량 예측결과
 Fig. 13. A forecasting result of LSTM current time solar power generation.




그림 14. RNN 24시간 후 발전량 예측결과
 Fig. 14. A forecasting result of RNN after 24 hours solar power generation.




그림 15. LSTM 24시간 후 발전량 예측결과
 Fig. 15. A forecasting result of LSTM after 24 hours solar power generation.

V. 결 론

기상청은 기상요소를 3일간 예보하지만 태양광 발전량 예측에 가장 중요한 기상요소인 일조 및 일사량 예보하지 않는다. 제안 모델은 예보 되는 기상요소를 이용하여, 일조 및 일사량을 예측 하였다. 본 연구에서 현재시각 일조 및 일사 예측은 예보 되는 기상요소를 이용한 일조 및 일사 예보라 할 수 있다. 또한, 발전량 예측은 예보되는 기상요소와 예보된 일조 및 일사 기상요소를 추가하여 예측하였다. 발전량 예측 결과 DNN의 평균 RMSE와 MAE는 0.177과 0.095이며, RNN은 0.116과 0.067이다. 또한, LSTM은 가장 좋은 결과인 0.100과 0.054이다. DNN의 경우 현재시각 예측부터 24시간 후의 예측까지 모든 예측 상황에서 발전량 데이터의 특징을 잡지 못해 시계열 데이터 학습에 적합한 RNN과 LSTM에 비해 예측율이 많이 떨어지는 것을 확인 할 수 있다. 향후 다양한 입력요소의 결합으로 보다 향상된 예측결과를 도출할 수 있을 것으로 기대된다.

Acknowledgement

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, May. 2017
- [3] 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
- [4] 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*, Vol. 8, No. 10, Mokpo: Korea, pp. 46-51, June. 2009
- [5] 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
- [6] 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
- [7] 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
- [8] K. H. Lee and 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
- [9] 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
- [10] 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
- [11] 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
- [12] 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
- [13] F. A. Gers, N. N. Schraudolph, and J. Schmidhuber, “Learning precise timing with LSTM recurrent networks,” *Journal of Machine Learning Research*, Vol. 3, No. 6, pp. 115-143, Mar. 2002
- [14] C. Olah, Understanding LSTM Networks, Github blog [Internet]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>.



신 동 하 (Dong-Ha Shin)

2016년 2월 : 가천대학교 에너지IT학과 (공학사)
 2016년 3월 ~ 현재 : 가천대학교 대학원 IT융합공학과 석사과정
 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