

제한적인 환경에서 현재 기온 데이터에 기반한 태양광 발전 예측 모델 개발

이현진*

요약

태양광 발전량은 날씨에 큰 영향을 받는다. 기상 예보를 사용할 수 있는 환경이라면, 기상 예보 정보를 사용하여 미래의 태양광 발전량을 단기예측 할 수 있다. 하지만, 섬이나 산과 같이 네트워크의 단절에 의해 기상예보 정보를 사용할 수 없는 제한된 환경에서는 기상예보를 사용한 태양광 발전량 예측 모델을 사용할 수 없다. 따라서 본 논문에서는 시스템 자체적으로 수집할 수 있는 정보만을 이용하여 태양광 발전량을 단기 예측할 수 있는 시스템을 제안하였다. 예측의 정확도를 높이기 위하여 이전 온도 정보와 발전량 정보를 이용하여 단기 예측모델을 생성하였다. 실험을 통하여 실데이터에 제안한 예측 모델을 적용하여 유용한 결과를 보였다.

키워드 : 태양광 발전 예측, 데이터 마이닝, 신경회로망, 기상 데이터

The Development of the Predict Model for Solar Power Generation based on Current Temperature Data in Restricted Circumstances

Hyunjin Lee*

Abstract

Solar power generation influenced by the weather. Using the weather forecast information, it is possible to predict the short-term solar power generation in the future. However, in limited circumstances such as islands or mountains, it can not be use weather forecast information by the disconnection of the network, it is impossible to use solar power generation prediction model using weather forecast. Therefore, in this paper, we propose a system that can predict the short-term solar power generation by using the information that can be collected by the system itself. We developed a short-term prediction model using the prior information of temperature and power generation amount to improve the accuracy of the prediction. We showed the usefulness of proposed prediction model by applying to actual solar power generation data.

Keywords : Prediction of solar power generation, Data mining, Neural networks, Weather data

1. 서론

석유 등 화석 연료 자원의 고갈, 환경 문제에

의한 탄소 배출 규제, 지진, 화산, 쓰나미 등에 의한 원자력 발전소의 위험성 등의 문제로 인해 태양광 발전, 풍력 발전 등 신재생에너지에 의한 전기 발전에 대한 수요가 증가하고 있다.

신재생 에너지를 초기에는 개인 주택에서 사용하는 전기 공급을 보조하기 위한 주택용 태양광 발전이나, 가로등이나 고속도로 전광판 등 공공 시설물에 대한 전기 수요를 충족시키기 위해서 소규모 태양광 발전에 적용하기 시작하였다. 최근에는 대규모 태양광 발전소를 구축하여 전력 회사에 판매하거나 도시의 전력 수요를 공급

※ Corresponding Author : Hyunjin Lee

Received: May 23, 2016

Revised: June 26, 2016

Accepted: June 29, 2016

* Dept. of Computer Science & Software, Korea Soongsil Cyber University

Tel: +82-2-708-7863, Fax: +82-2-708-7749

email: hjlee@mail.kcu.ac

하기도 한다. 섬이나 내륙 오지 등 전기 공급이 어려운 곳에서는 태양광 발전, 풍력 발전 등 다양한 신재생 에너지를 사용하고 있다.

발전소에 의해 공급되는 전기 생산의 보조수단으로 태양광 발전기를 사용할 때, 보다 섬과 같은 고립된 지역에서 이용되는 태양광 발전기는 전력생산에 미치는 영향력이 크기 때문에 태양광 발전량 예측이 중요하다. 또한 전력공급이 원활하도록 디젤 발전기와 같은 다른 발전기를 돌려야 한다. 이러한 다른 발전기의 운용계획은 태양광 발전량 예측에 따라 세울 수 있기 때문에 예측이 정확해야 디젤 발전기에 의해 생산되는 전기가 낭비되거나 부족하지 않게, 디젤 연료에 대한 수요 예측이 가능해진다. 에너지 저장장치(Energy Storage System : ESS)와 연계되면, 에너지 저장장치의 수명 연장을 위해서도 에너지 저장장치의 충전과 방전 사이클을 태양광 발전량의 예측에 의해 효율적으로 관리 할 수 있다.

태양광 발전량은 설비의 효율과 수명, 기상 변화, 위도 등 복합적인 요소에 영향을 받기 때문에 예측이 어려운 분야이다. 태양광 발전소를 건설하기 전에 해당 지역의 태양광 발전량을 예측하는 연구는 다양하게 이루어져 왔다. 일사량을 이용하여 태양광 모듈의 발전량을 예측하는 연구가 있었다[1][2]. 또한, 일사량, 일조시간, 운량 등에 의한 청명 일수와 위도와 해발 고도 등 다양한 데이터를 활용하여 태양광 발전 효율을 예측한 연구도 있었다[3]. 그리고 운량 예보를 활용하여 기존에 설치된 태양광 발전소의 발전량을 단기 예측한 연구도 있었다[4].

본 논문에서는 섬이나 산과 같은 오지에서 네트워크를 구성하기에는 비용상의 문제가 있거나 보안상의 문제로 네트워크가 제한된 상황에서 기상 예보 정보가 아닌 현재까지 측정하여 축적된 기상 정보를 사용하여 태양광 발전소의 발전량을 단기 예측하는 방법을 제안하였다. 발전량 예측의 결과가 디젤 발전기나 에너지 저장장치의 운용 계획과 연동될 수 있도록 1시간 단위로 48시간의 발전량을 예측하고, 기상 환경 변화에 바로 대응할 수 있도록 실행 시간(execution time, running time)을 초 이하의 실시간으로 수행되도록 하였다.

본 논문의 구성은 다음과 같다. 2장에서는 제

안하는 태양광 발전량 예측 모델에 대하여 살펴보고, 3장에서는 실 데이터를 사용하여 수행한 실험 결과를 분석하고 4장에서 결론을 맺는다.

2. 태양광 발전 예측 모델

2.1 제안하는 태양광 발전 예측 모델

본 연구에서는 네트워크가 제한된 환경에서 기 설치되어 있는 발전소에 최적화된 모델을 만들기 위한 태양광 발전 예측 모델을 구성하였다. 네트워크가 제한된 환경에서는 기상 예보 정보를 입력으로 사용할 수 없기 때문에 발전소에서 보유하고 있는 태양광 발전이력 데이터와 기상이력데이터를 사용하여 발전소에 최적화되어 있는 모델을 제안하였다. 입력 특징은 월, 일, 시, 온도, 발전량이며, 출력은 1시간 간격의 발전량(kwh)이다. 데이터는 12시간데이터를 기준으로 정규화 하였다. 예측 모델은 신경회로망 (neural networks)을 학습하여 생성하였다.

2.2 정규화

기본적인 태양광 발전 이력 데이터는 < 표 1>과 같다. 시계열 패턴과 관련된 날짜 정보인 월, 일, 시와 해당 시점의 온도 정보, 그리고, 해당 시점의 발전량 데이터로 구성된다.

<표 1> 태양광 발전 이력 데이터

year	month	day	hour	temp	kwh
2014	Jan.	1	10	7.2	55.20
2014	Jan.	1	11	10.0	63.78
2014	Jan.	1	12	12.8	62.73
2014	Jan.	1	13	15.0	56.47

<Table 1> Solar Power Generation Historical Data

네트워크가 제한된 환경은 기상 예보 정보를 받을 수 없을 뿐만 아니라, 사람이 운량과 같이 직접 데이터를 생성하는 것도 불가능하기 때문에 자동으로 수집할 수 있는 데이터인 온도와

발전량을 사용하였다.

입력 데이터는 현 시점 현 시점 기준 과거 이력 데이터를 사용하여 1시간 전 온도와 발전량부터 12시간 전 온도와 발전량까지 1시간 간격으로 생성하여 총 24개의 입력 패턴을 추가하였다. 현재 시점 기준 48시간의 데이터를 예측하기 위하여 목표(target) 변수로 현재 시점 기준 48시간의 데이터를 한 열(row)에 가지고 있어야 하기 때문에 1시간 후 발전량부터 48시간 후 발전량까지 1시간 간격으로 생성하여 총 48개의 목표 변수를 생성하였다.

2.3 신경회로망

신경회로망으로 태양광 발전을 예측하였다. 다층 퍼셉트론 (Multi-Layer Perceptron) 신경회로망으로 입력층, 은닉층, 출력층의 3개의 층으로 구성된다. 다층 퍼셉트론의 출력 $f(x)$ 는 식 (1)과 같다.

$$f(x) = K\left(\sum_i w_i x_i\right) \quad (1)$$

여기서, $K()$ 는 활성화 함수 (activation function)이다. 활성화 함수는 식(2)와 같이 로지스틱(Logistic)함수를 사용하였다.

$$K = \frac{1}{1 + e^{-x}} \quad (2)$$

x_i 는 입력 데이터이고, w_i 는 신경회로망 노드의 가중치(weight)의 값이다[7][8][9]. 신경회로망은 가중치 벡터를 변화시켜 학습이 이루어진다. 가중치 벡터를 학습시키는 방법을 다양하게 적용하여 모델을 구성하였다.

입력 노드는 시간 데이터 3개, 온도 데이터 12개, 발전량 데이터 12개인 27개를 사용했고, 은닉층의 개수는 1개이고, 은닉 노드의 개수는 입력 노드의 개수의 2배를 사용했다. 출력 노드는 48시간의 발전량을 나타내는 48개이다.

2.4 앙상블 학습

신경회로망의 성능을 높이기 위하여 여러 신경회로망 모델의 결과를 결합하는 앙상블 학습(Ensemble Learning)을 하였다[5].

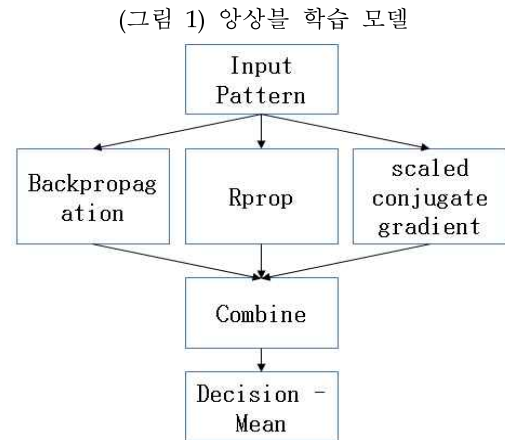
앙상블 알고리즘에 사용한 학습 알고리즘은 오류역전파(Backpropagation)와 RPRO(Resilient backpropagation), SCG (Scaled Conjugate

Gradient)를 사용했다. 오류역전파는 신경회로망 학습에 가장 많이 사용되는 방법이고[5], RPROP는 모든 패턴의 편미분의 부호를 고려하여 각 가중치를 독립적으로 학습하는 방법으로 빠른 학습을 보인다[6]. SCG 알고리즘은 에너지 최소화와 같은 제약이 없는 최적화 문제를 해결하는데 많이 사용한다[7].

각 알고리즘의 학습 결과는 부스팅(Boosting) 기법을 사용하여 조합하였다. 부스팅은 식(3)과 같이 각 모델의 결과에 가중치를 곱하여 새로운 모델을 생성한다.

$$F(x) = \alpha_1 f_1(x) + \alpha_2 f_2(x) + \alpha_3 f_3(x) \quad (3)$$

본 논문에서는 세 모델의 가중치 $\alpha_1, \alpha_2, \alpha_3$ 를 모두 동일하게 $\frac{1}{3}$ 로 할당하였다. 사용한 앙상블 학습의 구성도는 다음 (그림 1)과 같다.



(Figure 1) Ensemble Learning Model

2.5 비교대상 예측 알고리즘

신경회로망의 결과와 성능을 비교하기 위하여 ARIMA[8]와 GLM[9]를 사용했다. ARIMA (Atogressive Integrated Moving Average) 알고리즘은 시계열 분석 알고리즘의 일종으로 시계열 데이터에 대한 단기 예측에 많이 사용하고 있다[10][11]. ARIMA는 단일변량기법으로 시계열의 분산이 변하거나 계절성을 가지고 있을 때 안정적으로 동작할 수 있는 알고리즘이다.

선형 회귀 분석은 종속 변수가 정규분포와 등분산을 가지는데, 실제 관측값과 일치하지 않는 경우가 많다. 이런 문제점을 해결하기 위하여 자

료의 독립성과 비정규분포의 자료에 대한 분석이 가능한 것이 일반화 선형 모형(Generalized Linear Model : GLM)이다.

일반적으로 일반화 선형 모형은 식(4)와 같다.

$$E(Y) = g^{-1}(X\beta) \quad (4)$$


여기서 Y 는 서로 독립인 $n \times 1$ 확률 변수를 나타내고, $E(Y)$ 는 목표값이다. X 는 독립 변수로 이루어진 $n \times p$ 공변량 행렬 (covariance matrix)이고, β 는 $p \times 1$ 행렬이며, $X\beta$ 는 선형 예측식 (linear predictor)라고 하고, g 는 연결 함수 (link function)이다.

3. 실험환경 및 결과

3.1 실제 발전량 데이터 분석

본 논문에서 사용한 데이터는 캘리포니아 태양 에너지 통계(California Solar Statistics)에서 제공하는 공개된 발전량 데이터로 미국 캘리포니아에 있는 태양광 발전기에 대하여 2010년 10월부터 2015년 8월까지 15분 간격으로 수집된 데이터이다 [12]. 캘리포니아 태양 에너지 통계의 2014년도의 발전량 데이터를 분석하면 (그림 2)와 같다.

(그림 2) 연간 태양광 발전량의 변화 추이



(Figure 2) Annual solar power generation trends.


캘리포니아 태양 에너지 통계의 태양광 발전소 중 옐로(Yolo)주 데이비스(Davis)시에 있는 발전소를 사용하였다. 데이비스시는 전형적인 지중해 기후로 여름에는 건조하며 덥고, 겨울에는 시원하고 비가 자주 온다. 발전량은 겨울보다는 여름에 더 많다. 우리나라는 여름에 덥고 비가 많이 오고,

겨울에 춥고 눈이 오기 때문에 우리나라의 발전량 분포는 이와 상이하다.

(그림 2)는 주기성을 보이고 있어서 시계열 분석으로 단기 예측을 할 수 있지만, 시계열 분석은 비, 눈, 구름, 안개 등 돌발적인 기상 변화를 고려하지 않기 때문에 이에 빠르게 대응할 수 없다. 15분 간격으로 기록한 최소 발전량은 1.0 kWh이고, 최대 발전량은 37.5 kWh이다. 0인 경우는 야간에 태양이 없어서 나타난 데이터로 이 시점을 제외한 최소값을 기준으로 하였다. 발전량 데이터는 15분 단위로 측정된 것으로 1시간 데이터로 누적하면, 더 높은 값이 생성된다.

발전량의 변화를 자세히 분석하기 위해 (그림 3)과 같이 3일간의 발전량을 분석하였다. 7시 경에 일출이므로 그 이전은 0이고, 그 이후에 서서히 증가해서 12시 경에 최대치에 이른다. 그 후 일몰 시간인 5시 경까지 지속적으로 감소하고, 그 후에 0의 발전량을 보인다. 단기간에는 시계열 경향이고, 48시간의 발전량 예측의 결과는 봉우리가 2개 있는 산의 형태이다.

(그림 3) 3일간의 태양광 발전량의 변화 추이




(Figure 3) Trends in the solar power generation in 3 days.

3.2 온도 데이터와 발전량의 관계

태양광 발전기의 발전량은 일사량과 직접적인 관계가 있다. 태양광 발전 예측 연구들에서는 일사량이 중요한 요소이다[1][2][3][4]. 하지만, 본 논문에서 사용한 Friendly Forecast의 기상 데이터[13]에는 일사량 데이터가 존재하지 않는다. Friendly Forecast의 기상 데이터는 시간 단위로 측정된 데이터로 온도, 기압, 가시성, 습도를 수집하고 있기 때문에 태양광 발전량에 밀접한 관

계가 있는 온도를 특징으로 하였다.

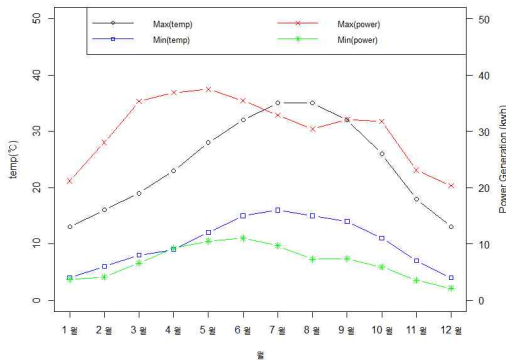
(그림 4) 연간 온도 변화 추이



(Figure 4) Annual temperature trends.

올로주에 위치한 데이비스시의 연평균 기온을 살펴보면 (그림 4)와 같다. (그림 2)와 비교해 보면, 연평균 기온이 높은 여름의 발전량이 연평균 기온이 낮은 겨울의 발전량에 비해서 더 높다. 즉, 기온과 태양광 발전량 사이에도 밀접한 관련이 있다.

(그림 5) 연간 온도와 태양광 발전량 변화 추이



(Figure 5) Annual temperature and solar power generation trends.

태양에 의한 기간 별 기온의 변화 추이와 발전량의 변화 추이는 (그림 5)와 같다. 온도와 태양광 발전량은 상관도가 높다. 온도와 태양광 발전량의 상관관계를 피어슨 상관계수(Pearson's Correlation Coefficients)로 살펴보면, 0.728이다.

상관계수 값이 0.9보다 크면, 두 변수 사이에 선형인 관계가 있고, 0.7 ~ 0.9 사이이기 때문에, 온도와 태양광 발전량은 밀접한 관계이다[14].

3.3 실험 데이터

태양광 발전에 중요한 요소는 태양광이다. 조도를 예측하거나 예보 받을 수 있으면, 태양광 발전량 예측의 정확도는 높아진다. 본 논문에서는 예보정보를 받을 수 없는 제한된 환경에서 태양광 발전량을 예측해야 하기 때문에 태양광 발전을 예측하는 기본적인 입력요소는 월, 일, 시의 시간 정보로 하였다. 1시간 전부터 12시간 전까지에 대한 과거 온도 12개, 과거 발전량 12개, 온도 예보 12개를 입력 요소 후보로 하였다.

3.1절의 올로주의 데이터에 대해, 2014년 데이터를 학습 데이터로, 2015년의 5개월 데이터를 테스트 데이터로 사용했다. 데이터 집합은 기본 입력 요소 3개는 모두 사용한 상태에서 아래 <표 2>와 같이 보조 입력 요소를 조합하여 6개의 데이터 집합을 생성하여 최적의 입력 요소를 찾는데 사용하였다.

<표 2> 데이터 집합

Name	Time	Past Temperature	Past Generated Power	Forecast Temperature
data1	O	x	x	x
data2	O	O	x	x
data3	O	O	O	x
data4	O	x	O	x
data5	O	x	O	O
data6	O	O	O	O

<Table 2> Data set

data1에서 data4는 네트워크가 제한적인 환경에서 수집할 수 있는 데이터이고, data5와 data6은 네트워크가 가능한 상황에서 기상 예보 정보를 사용한 데이터이다. data1 ~ data4의 입력을 사용한 예측 모델이 기상 예보 데이터를 사용한 data5, data6를 사용한 예측 모델과 근접한 성능을 보이는 것을 목표로 한다.

3.4 신경회로망 실험 결과

<표 3>은 오류역전과 학습 신경회로망을 이

용하여 예측한 결과이다. 성능은 식(5)와 같이 오차 제곱합(Sum of Squared Error : SSE)으로 계산하였다.

$$SSE = \sum (Y - \hat{Y})^2 \quad (5)$$

Y는 목표 값이고, \hat{Y} 모델에 의해 생성된 값이다. 오차 제곱합이 작을수록 성능이 우수한 것이다.

<표 3> 신경회로망으로 학습한 결과

DataSet	training result	test result
data1	329.79	144.73
data2	273.34	679.52
data3	243.53	105.95
data4	293.43	120.50
data5	266.45	437.47
data6	253.68	102.13

<Table 3> Result of Neural Networks

data6의 성능은 테스트 데이터에 대해서 우수하다. 이 데이터는 온도 예보와 과거 온도, 과거 발전량을 모두 이용하여 예측한 것으로 예보 정보를 이용하기 때문에 가장 좋은 성능을 보인다. 제약이 있는 상황에서 사용할 수 있는 과거 발전량과 과거 온도를 이용한 경우인 data3은 학습 데이터에 대해서는 가장 성능이 우수하고, 테스트 데이터에 2번째로 성능이 우수하였다.

3.5 다른 알고리즘과의 비교

<표 4>는 data4를 제안하는 앙상블 알고리즘 (Ensemble)과 GLM, ARIMA에 적용한 결과이다. ARIMA는 수집된 데이터를 활용한 단기 예측으로 특정 시점 또는 특정 입력에 대한 결과를 보이는 것이 아니라, 현재 시점 기준으로 앞으로의 데이터를 예측하기 때문에 테스트 데이터(test data)는 학습데이터(training data)이후 48시간의 데이터에 대한 결과를 비교하였다.

ARIMA는 학습데이터에 대한 예측을 수행하지 않으므로 학습데이터에 대한 성능이 나올 수 없다. 학습데이터에 대한 오차 제곱합은 앙상블 알고리즘이 GLM 보다 우수 하였다. 테스트데이터에 대한 결과는 GLM의 성능이 가장 낮았다. ARIMA와 앙상블 알고리즘을 비교했을 때 앙상블 알고리즘의 성능이 2.4배 우수하였다.

<표 4> 알고리즘 간의 비교

Algorithms	training result	test result
Ensemble	54.36	0.30
glm	295.90	3.65
ARIMA	x	0.734

<Table 4> Comparison between Algorithms

(그림 6)은 학습데이터 이후 48시간의 발전량 데이터를 예측한 그래프이다.


(a) ARIMA 방법은 24시간까지의 유사도는 0.05이고, 25시간에서 48시간까지의 유사도는 0.685로 후반부에 저하되었다. ARIMA는 태양광 발전량 예측에 사용할 때는 24시간 이내의 초단기 예측을 위해서만 사용할 수 있다. 또한, ARIMA의 특성상 특정 시점 이후의 값을 예측하기 위해서는 ‘데이터 수집 - 모델 생성 - 예측’의 단계가 필요하기 때문에 예측시간이 오래 걸린다. ARIMA의 모델링 시간과 예측 시간은 3분 30초가 소요되었다. 따라서 실시간 예측 환경에는 적합하지 않다.

(b)일반화 선형 모형 방법은 태양이 없어 발전량이 0이 나와야하는 구간의 데이터에 대해 부정확하여 발전량 예측에 부적합하다. 일반화 선형 모형의 모델링 시간은 1초이고, 가 소요되었고, 48시간의 데이터에 대한 예측시간은 0.0002033898초 이다.


(c) 앙상블 방법은 24시간까지의 유사도는 0.147이고, 25시간에서 48시간까지의 유사도는 0.154로 전반과 후반사이의 성능은 유사하였다. 발전량이 증가하는 시점에서의 정확도는 떨어지지만, 0인 시점과 발전량이 감소하는 시점의 데이터는 일치하였다. 신경회로망의 모델링 시간은 60.8초가 소요되었고, 48시간의 데이터를 예측하기 위해서는 0.0000338983 초가 소요되었다.

제안하는 앙상블 태양광 발전량 예측 모델을 재사용할 수 있는지를 확인하기 위하여 24일간의 데이터를 48시간 간격으로 적용하였다. 2015년 1월 1일 0시, 2015년 1월 3일 0시, 2015년 1월 5일 0시에서 2015년 1월 23일 0시까지 적용한 결과는 (그림 7)이다. 24일 간의 예측 성능은 3.736으로 재사용이 가능한 정확도를 보였다.

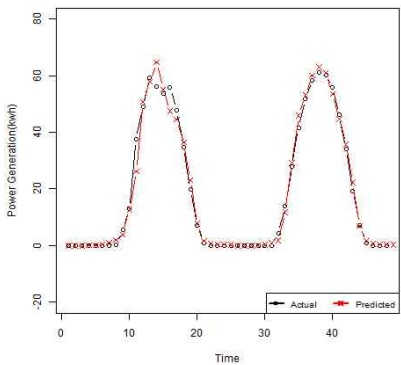
(그림 6) 알고리즘 간의 비교



(a) ARIMA




(b) GLM



(c) Ensemble

(Figure 6) Comparison between Algorithms

(그림 7) 앙상블을 이용한 장기 예측



(Figure 7) Long term predict result by Ensemble model

4. 결론

본 논문에서는 섬이나 산과 같이 네트워크가 제한된 상황에서 태양광 발전량 예측을 연구하였다. 기상 예보 정보 없이 현 시스템에서 수집된 12시간의 과거 온도 데이터와 12시간의 발전량 데이터를 입력으로 사용하여, 앙상블 알고리즘으로 예측 모델을 만들었다. 기상 예보 데이터를 사용한 예측 모델과 성능 차이가 크지 않았고, 실 데이터에 적용한 결과 태양광 발전량을 단기 예측할 수 있는 것을 확인하였다.

본 연구에서 온도와 발전량을 활용하였으나 추가적으로 다양한 기상 데이터로 관측할 수 있는 운량, 강수량과 센서를 통해 수집할 수 있는 기압, 일사량 데이터, 태양과 전지판에 대한 정보인 태양과 전지판의 먼지량, 그림자 여부 등의 특징을 데이터로 사용할 수 있다면 예측 성능을 향상시킬 수 있을 것이다.

한 번 만들어진 예측 모델은 초기에 만들어진 성능이 시간이 경과할 수로 저하된다. 네트워크가 제한된 환경에서는 예측 모델을 수동으로 갱신하기 어렵기 때문에 지속적으로 사용하기는 어렵게 된다. 따라서 이러한 것을 보완하기 위하여 예측 모델을 자동으로 갱신할 수 있는 온라인 학습(Online Learning)에 대한 연구가 필요하

다.

References

[1] M. Detynicki, C. Marsala, A. Krishman, and M. Siegel, "Weather-based solar energy prediction," WCCI 2012 IEEE world cong. on computational intelligence, pp. 1-7, June, 2012.

[2] A. Prastawa, and R. Dalimi, "New Approach on Renewable Energy Solar Power Prediction in Indonesia based on Artificial Neural Network technique: Southern region of Sulawesi island study case," 2013 International Conference on Quality in Research, pp. 166-169, 2013.6.

[3] W. C. Cha, J. H. Park, U. R. Cho, 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, 2014.

[4] K. D. Kim, "The Development of the Short-Term Predict Model for Solar Power Generation," Journal of the Korean Solar Energy Society, Vol.33, No.6, 2013.

[5] Rokach, L. "Ensemble-based classifiers", Artificial Intelligence Review, Vol. 33, pp. 1 - 39, 2010.

[6] Christian Igel and Michael Hüsken, "Empirical Evaluation of the Improved Rprop Learning Algorithm", Neurocomputing, Vol. 50, pp. 105-123, 2003.

[7] Avriel, and Mordecai, "Nonlinear Programming: Analysis and Methods", Dover Publishing, 2003.

[8] Durbin J. and Kouppman, S.J. "Time Series Analysis by Static Space Methods", Oxford University Press, 2001.

[9] Gareth James, Daniela Witten, Trevor Hastie and Robert Tibshirani, "An Introduction to Statistical Learning with Applications on R", Springer, 2013.

[10] C. B. Kim "Forecasting the Seaborne Trade Volume using Intervention Multiplicative Seasonal ARIMA

and Artificial Neural Network Model", Journal of Korea Port Economic Association, Vol.31, No.1, pp.69-84, 2015.

[11] M. S. Kim, K. W. Kim, S. S. Park, "A Study on the Air Travel Demand Forecasting using time series ARIMA-Intervention Model," Journal of the Korean Society for Aviation and Aeronautics, Vol. 20, No.1, pp.63-74, 2012.

[12] https://www.californiasolarstatistics.ca.gov/data_downloads/

[13] <http://www.friendlyforecast.com/>

[14] David S. Moore, William I. Notz, and Michael A. Fligner, "The Basic Practice of Statistics", W. H. Freeman, 2015.



이 현 진

1996년: 순천향대학교 전산학과
공학사

1998년: 연세대학교 대학원 컴퓨터
과학과 공학석사

2002년: 연세대학교 대학원 컴퓨터
과학과 공학박사

2003년~현재: 숭실사이버대학교

컴퓨터소프트웨어학과 부교수

관심분야 : 이터닝, 기계학습, 빅데이터