

태양광 발전량 예측을 위한 빅데이터 처리 방법 개발

정재천^{1)*}, 송치성²⁾

1) 한전국제원자력대학원대학교, 2) 한국기계연구원

Development of Solar Power Output Prediction Method using Big Data Processing Technic

Jae Cheon Jung^{1)*}, Chi Sung Song²⁾

1) KEPCO International Nuclear Graduate School

2) Korea Institute of Machinery and Materials

Abstract : A big data processing method to predict solar power generation using systems engineering approach is developed in this work. For developing analytical method, linear model (LM), support vector machine (SVN), and artificial neural network (ANN) technique are chosen. As evaluation indices, the cross-correlation and the mean square root of prediction error (RMSEP) are used. From multi-variable comparison test, it was found that ANN methodology provides the highest correlation and the lowest RMSEP.

Key Words : Solar Power, Output Prediction, Big Data, Accuweather, Systems Engineering, Weather Forecast, LM (Linear Model), SVM (Support Vector Method), ANN (Artificial Neural Network), RMSEP (Root Mean Square Error Prediction), MOP (Measure of Performance), TPM (Technical Performance Measure)

Received: April 28, 2020 / **Revised:** June 15, 2020 / **Accepted:** June 17, 2020

* 교신저자 : Jae Cheon Jung, jjung@kings.ac.kr

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.

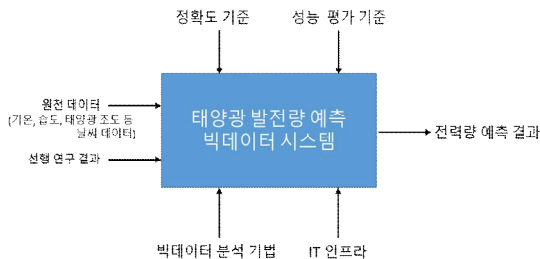
1. 개발 방법론 개요

1.1 빅데이터 처리 프로세스

빅데이터(Big Data)란, 기존 데이터베이스 관리 도구의 능력을 넘어서는 대량의 정형 또는 비정형의 데이터 집합을 포함한[1] 데이터로부터 가치를 추출하고 결과를 분석하는 기술[2]이다. 빅데이터 모델은 ‘대량, 고속 또는 다양한 정보 자산 (3 V) 모델로 정의할 수 있다[3]. 본 연구와 같이 다변수/대량 데이터를 처리하고 분석하기 위해서는 빅데이터 처리기법과 도구가 필수적이다.

본 연구에서 수립된 개발 개념이 시스템으로 설계되기 위해서는 각각의 기상예보 변수를 개별적으로 분석하기 보다는 시스템적 관점에서의 이해하는 것이 필요하다[4]. 특히 처리해야 할 부가데이터 량이 증가할 경우 이를 자동으로 분석하고 빠른 시간 내에 결과를 제공하는 것이 필수적이다. 그림 1은 본 연구를 통해 수립된 빅데이터 분석을 통한 ‘태양광 발전량 예측 시스템’의 최상위 수준(Level 0) 컨텍스트(Context) 다이어그램이다.

본 빅데이터 시스템의 원천 데이터로는, 일기 예보의 기본 데이터인 기온, 습도 이외에도 태양광 조도 등의 빛의 세기와 관련된 데이터, 시간대 별 태양광 패널의 발전량 추이 등이 입력으로 사용된다. 아울러 태양광 발전량 예측 시스템에 관한 선행 연구결과도 사용된다. 이 중에서 ‘하루 단위 태양광 발전량을 일기예보 정보를 이용해 예측하는 방법[5]’과 ‘머신러닝을 이용한 예측방법[6][7]’, 그리고 ANN을 이용한 예측방법[8]이 참조되었다. 인어블러



[Figure 1] Context diagram of Big data system for the prediction of solar power generation (Level 0)

(Enabler)로는 다음의 세 가지 분석이 활용되었다.

- 서포트 벡터 머신(SVM, Support Vector machine)
- 선형 모델(LM, Linear Model)
- 인공신경망(ANN, Artificial Neural Network)

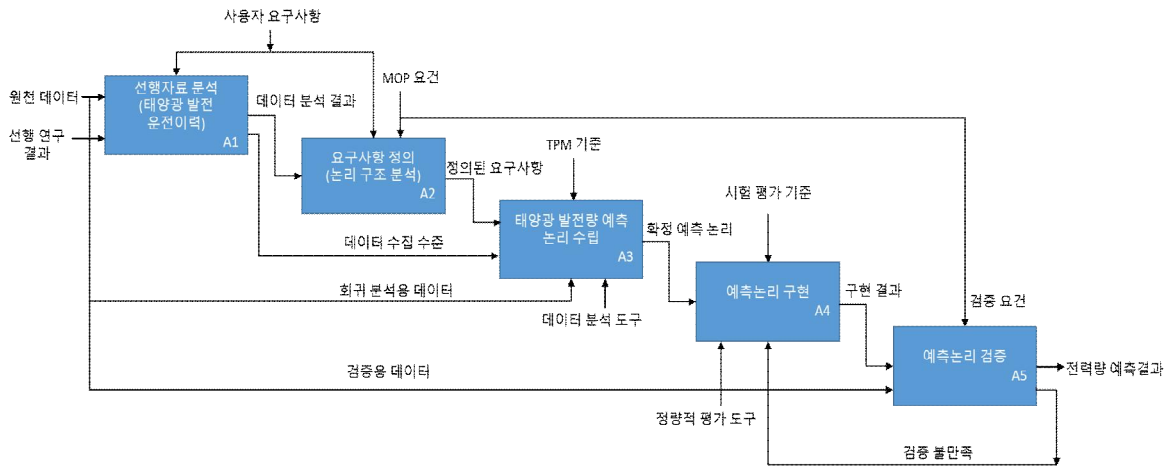
본 연구에서는 초기 정확도 기준과 성능 기준을 다음과 같이 수립하였다. 이 단계는 시스템 요건 정의 프로세스에서 요구하는 성능평가척도(MOP, Measure of Performance) 설정에 해당한다.

- 정확도 기준 : 예측 전력량과 측정 전력량의 상관도가 99% 이상일 것
- 예측오차의 제곱평균제곱근 (RMSEP) 기준 : 80 미만일 것

그림 2는 본 연구에서 제안하는 시스템의, 수준 1 전개결과를 보여준다. 이 단계는 시스템엔지니어링 핸드북 4.0의 기술 프로세스[9] 중 아키텍처 및 설계정의 단계와 시스템 분석 단계의 필수 활동에 해당한다.

기술성능척도(TPM)는 최종 구현 결과를 평가하기 위한 것으로서, 요구사항 정의 단계의 MOP로부터 도출된 정확도와 성능 평가 기준을 이용하여 설정하였다. 본 연구에서의 TPM은 다음과 같다.

- 입력 데이터 처리 및 분석용 소프트웨어 코드는 가급적 200라인 이내로 작성할 것 : 코드가 길어지면 실행시간이 길어지고 간결성이 유지될 수 없음
- 과도한 외부 라이브러리 함수(Library Function) 사용을 배제할 것 : ANN에 적용되는 많은 라이브러리 함수는 대부분 블랙박스 형태로 구현되어 검증이 불가함
- ANN의 에포크(Epoch)의 수가 10개 이내일 것 : 에포크가 많아지면 오실레이션 및 발산의 가능성이 있음
- ANN의 시험 및 검증에 요구되는 일기예보 데



[Figure 2] Level 1 Context Diagram

이터가 1시간 이력단위 이내일 것 : 데이터 배치(Batch)처리 시간의 적정성을 유지하기 위함

1.1.1 수준 1 전개

먼저 입력된 원천 데이터와 선행연구결과를 이용하여 선행자료를 분석한다. (단계 A1). 날씨 정보 어플리케이션 (Accuweather [10])에서 제공하는 시간대 별 날씨 데이터를 이용해 해당 태양광 패널의 시간이력 출력데이터와 비교하는 절차가 필요하다. 그러나 전력량을 시간 단위로 예측하려면 다음과 같은 추가적인 데이터가 있어야 한다.

- 평균 경사 태양 복사량
- 평균 수평 태양 복사량

문제는 이러한 데이터는 Accuweather[10]에서 제공하지 않는다는 것이다. 따라서 본 선행자료 분석 단계에서는 가용 데이터를 기반으로 이러한 요소를 예측하기 위한 논리적인 모델이 요구사항 정의 (단계 A2)를 통해 결정되어야 한다. 이 단계는 데이터 분석결과를 입력으로 사용한다. 상기 두 단계는 사용자 요구사항과 이를 통한 성능 평가척도에 의해 영향을 받는다. 특히 예측 정확도는 전력거래에 따른 수익과 직결되므로 가용한 범위에서 극대화하는 것이 필요하다. 전술한 바와 같이 예측 논

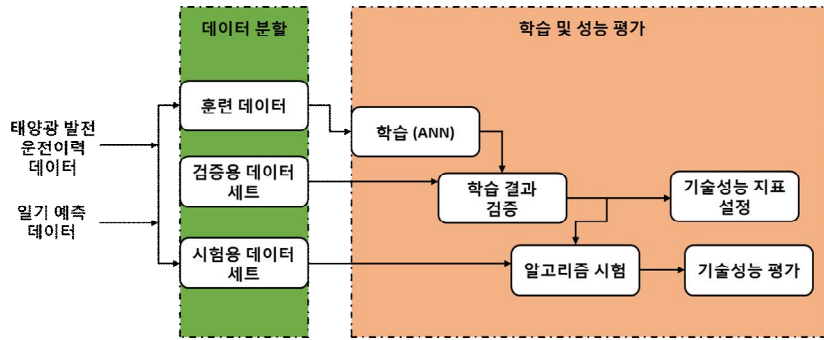
리의 구현 (단계 A3)을 위해서는 데이터 분석도구가 인어블러로 사용되고, 기술성능척도가 통제요소로 이용된다. 실제적인 예측논리 구현 (단계 A4)은 시험 평가 기준에 의해 수행한다. 구현결과는 학습과 검증을 거쳐 훈련되고, 별도의 시험 데이터를 이용해 적합성을 판단하게 된다. 만일 시험 결과가 불만족으로 판정되면 이 결과는 A4 단계의 참조 항목으로 되돌려져 예측논리를 정제하는데 이용된다.

1.2 빅데이터 분석을 위한 도구와 방법

1.2.1 서포트 벡터 머신 (SVM) 개요

회귀 분석과 같이 데이터 분류에 많이 사용되는 SVM은 기계 학습의 분야 중 하나로 패턴 인식, 자료 분석을 위한 지도 학습 모델이며, 주로 분류와 회귀 분석을 위해 사용한다.

SVM은 초평면(hyperplane) 또는 초평면들의 집합으로 구성되어 있다. 직관적으로, 초평면이 가장 가까운 학습 데이터 점과 큰 차이를 가지고 있으면 분류 오차가 작아지므로 좋은 분류를 위해서는 어떤 분류된 점에 대해서 가장 가까운 학습 데이터와 가장 먼 거리를 가지는 초 평면을 찾아야 한다. SVM의 계산량이 늘어나는 것을 막기 위해서, 각 문제에 적절한 커널 함수 $k(x,y)$ 를 정의한 SVM 구조를 설계하여 내적 연산을 초기 문제의 변수들을



[Figure 3] Data split and training processes of ANN

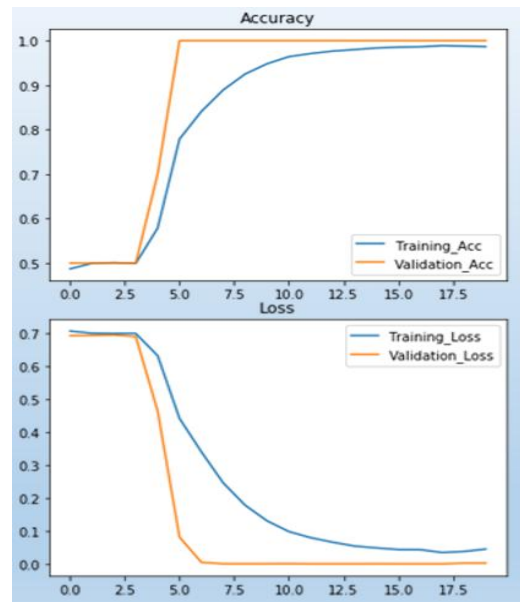
사용해서 효과적으로 계산할 수 있도록 한다[3]. 높은 차원 공간의 초평면은 점들의 집합과 상수 벡터의 내적 연산으로 정의된다. 초평면에 정의된 벡터들은 데이터베이스 안에 나타나는 이미지 벡터 매개변수들과의 선형적 결합이 되도록 선택된다.

1.2.2 인공신경망(ANN) 개요

그림 3에서 나타나듯이 ANN을 구현하기 위해, 태양광 패널의 운전이력 데이터(발전량 데이터와 날씨 데이터)가 입력되어야 한다. ANN에서는 데이터를 훈련용 데이터와 검증용 데이터, 시험용 데이터 세트의 3가지로 분류한다. ANN의 학습 단계는 훈련과 검증으로 나뉘는데, 전체 훈련용 데이터 중 75%는 학습에 사용하고, 25%는 검증을 위해 사용한다.

이를 통해 ANN 알고리즘의 최적화를 이루게 된다. 과도한 에포크는 발산을 유도하므로 에포크를 최적화하기 위한 분석을 수행한다. 그림 4는 시뮬레이션을 위해 임의로 생성시킨 데이터를 이용하여 훈련한 결과(출력)의 정확도와 손실을 나타낸 것이다. 그림과 같이 12 에포크(Epoch)를 지나면 손실률의 개선 정도가 미미하고, 정확도 역시 더 이상 높아지지 않음을 알 수 있다. 따라서 본 연구에서는 에포크의 상한을 10으로 설정하였다.

정확도를 평가하는 성능평가 지표로는 절대평균 오차(MAE)와 제곱평균오차(MSE) 방법, 그리고 평균 제곱근오차(RME)가 일반적으로 사용된다. 절대평균 오차법은 예측 결과가 얼마나 실제 측정 결



[Figure 4] Training accuracy (top) and loss (bottom) term

과와 가까운지를 나타낸다. 제곱평균오차 역시 MAE 방법과 유사하며 제곱 오차가 얼마나 실제와 근사하는지를 보여준다. 이외에도 평균 제곱근 오차도 사용된다. 이는 MSE의 근을 취한 것이다. 공식으로 표현하면 표 1과 같다.

ANN 처리 층에서는 특이점 추출단계와 분류단계로 나누어 심화학습을 시킨다. 이미 설명한 바와 같이 기계학습은 입력신호와 출력신호를 이용하여, 입, 출력 간 어떠한 규칙을 갖는지를 찾아내기 위한 학습이 필요하다. 또한 학습의 결과가 제대로 된 것 인지를 판단하기 위한 검증의 단계도 아울러 요구된다.

<Table 1> Measure of Performance

- **절대평균 오차 (MAE):**

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}_i|$$
- **제곱평균 오차 (MSE):**

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2$$
- **평균 제곱근 오차 (RMSE):**

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2}$$


2. 예측 모델 구현을 위한 4단계

그림 5는 일기예측 데이터와 태양광 발전 운전이력 데이터를 입력으로 한 예측모델 구현의 4단계를 보여준다.

본 알고리즘의 구현을 위해 표 2의 9가지 날씨 입력 데이터가 사용되었다. Accuweather에서 제공하는 정보는 태안군 석문면 교로리 일대에 동서발전이 10MW 규모로 건설한 태양광 발전소의 지역의 3월 6일과 7일 정보를 이용하였다. 또한 날씨 별 태양광 발전량을 시각 동기화하여 KW 단위 입력으로 사용하였다. 이러한 예측모델 구현을 위한 프로그래밍 도구로서 R-Studio가 이용되었다. 이와 함께 데이터 가시화를 위해 Microsoft Excel도 아울러 사용되었다.

2.1 데이터 전 처리

전 처리를 위한 데이터는 원본 데이터와 추가 날씨 정보의 두 가지 데이터 세트로 구성된다. 본 분석에 사용된 원본 데이터 열은 다음과 같다.



[Figure 5] Four(4) Steps for implementing prediction model

<Table 2> Weather Input Data

온도	누적 강수량
풍향	풍속
국지 기압	해수면 기압
습도	태양광 조도
태양광 조사 기간	

- 날짜와 시간
- 햇빛의 강도
- 주변 온도
- PV 모듈 온도
- 총 전력 출력(AC)

상기의 데이터에는 주어진 시간 동안 날씨 정보를 상관시킬 수 있도록 날짜 및 시간 데이터가 포함되었다. 이 데이터 열은 R-Studio에서 처리할 수 있도록 CSV 형식으로 변환하였다.

2.1.1 데이터 모델 정의

위에서 소개한 바와 같이 Accuweather에서 제공하는 날씨 데이터를 사용하였다. 또한 모든 데이터는 본 분석과 연관성이 있다는 가정 하에 분석용 데이터 세트를 작성하였다. 빅데이터를 컴퓨터가 신속하게 처리하도록 하기 위해, 특정 시간 (원래 데이터에서와 같이 15 분마다)의 날씨 정보 추출을 위한 데이터 필터링과, 원본 데이터와 결합하는 과정을 거쳤다. 또한, ANN 및 SVM 알고리즘의 학습과 검증, 그리고 정합성 시험을 위해, 데이터를 다음과 같이 두 세트로 분할하였다.

- 훈련 (학습과 검증)용 데이터 세트
- 시험용 데이터 세트

단, 훈련과 시험을 위한 데이터 분할은 인위성이 개입되지 않도록 무작위로 수행토록 프로그램을 작성하였다.

2.1.2 최적 모델의 선정

초기 모델의 분석 평가를 위해 SVM과 LM 를 대상으로 하여 그 결과값을 판독한 결과, LM의 회귀 분석식이 SVM보다 우수한 성능을 보이는 것을 확인하였다. 아울러 LM의 상대적 성능을 확인하기 위해 추가 알고리즘인 ANN을 적용하였다.

2.1.3 모델 훈련 및 시험

3가지 모델을 R-studio로 개발한 후, 훈련 데이터를 사용하여 학습을 수행하고, 시험 데이터를 사용하여 시험하였다. 시험 단계에서 예측된 결과는 측정/예측 데이터 간의 상관관계로 평가하였다. 식 (1)은 정확성 평가기준으로 적용된 상관도 분석 공식이다.

$$R^2 = \frac{\sum_{i=1}^n (x_i - \hat{x}_i)(y_i - \hat{y}_i)}{(n-1)S_x S_y} \quad (1)$$

여기서, \hat{x}_i = 표본집단 x 의 평균

\hat{y}_i = 표본집단 y 의 평균

S_x = 표본집단 x 의 표준편차

S_y = 표본집단 y 의 표준편차

n = 표본집단 개체수

3. 태양광 예측모델 개발 및 분석

3.1 모델 간 회귀 분석 결과

상기의 선형 회귀선을 1차 방정식으로 표기한 결과와 이때의 상관도 R^2 를 표 3에 나타냈다.

<Table 3> Linear regression and cross-correlation (R^2) per models


Model	Linear regression of Model	Cross-correlation (R^2) Measured/Predicted
SVM	$y = 0.9607x + 45.294$	$R^2 = 0.9908$
LM	$y = 0.9766x + 6.8309$	$R^2 = 0.9917$
ANN	$y = 0.9926x - 3.205$	$R^2 = 0.9946$

식 (2)는 본 선형 모델을 1차 방정식으로 표현한 것이다. 이미 설명된 바와 같이 Accuweather가 제공하는 모든 측정 변수가 활용되었음을 알 수 있다.

$$\begin{aligned} \text{발전량}(KW) = & (-0.266 * \text{온도}) + (-1.156 * \text{강수량}) + (0.0807 * \text{풍향}) \\ & + (1.66 * \text{풍속}) + (294.755 * \text{국지 기압}) + (-294.40 * \text{해수면기압}) + (-.155 * \text{습도}) \\ & + (3.522 * \text{태양광조사시간}) + (2.773 * \text{태양광조도}) + (-18.544 * \text{대기온도}) \\ & + (10.49 * \text{모듈 온도}) + 721.0539 \end{aligned} \quad (2)$$

상기 식 (2)에서 국지 기압과 해수면 기압 변수는 상쇄할 수 있음을 알 수 있다. 상기 회귀식과 상관도를 적용 LM 모델과 ANN 모델로 가시화 한 결과는 그림 6과 같다. 단, SVM 모델의 결과는 LM과 유사하여 제외하였다. 표 4는 본 연구에 적용된 성능 평가 척도 중 평균 제곱근 오차를 상관도와 같이 표기한 것이다. ANN모델의 상관도 R^2 가 가장 높고 예측 오차는 가장 낮음을 알 수 있다.

분석 1을 좀 더 단순화하기 위해 선형모델에서



[Figure 6] Visualization of regression model (top : LM, bottom : ANN)

<Table 4> MOP Results (Cross-correlation and RMSEP)

Model	Cross-Correlation	RMSEP
SVM	0.9908	104.315
LM	0.9917	95.439
ANN	0.9946	76.114

기압 변수를 제거하고 난 후 LM과 ANN 만을 대상으로 재분석을 실시하였다. 두 모델의 훈련 및 시험 결과는 그림 6과 같다.

선형 모델에서 AC 전력과 측정된 매개 변수 간의 관계는 다음 식 (3)과 같이 표기할 수 있다. 상관 관계는 LM과 ANN이 각각 0.992와 0.9952를 보여 기압 변수를 적용한 경우와 차이가 크지 않았음을 알 수 있다.

$$\begin{aligned}
 \text{발전량(KW)} = & (4.954 * \text{온도}) + (-1.195 * \text{강수량}) \\
 & + (0.0835 * \text{풍향}) + (1.941 * \text{풍속}) + (-0.636 * \text{국지기압}) \\
 & + (-0.246 * \text{습도}) + (2.696 * \text{태양광조사}) + (-0.0014 * \text{태양광조사시간}) + (2.785 * \text{태양광광도}) \\
 & + (-17.896 * \text{대기온도}) + (9.439 * \text{모듈온도}) + 647.1105
 \end{aligned}
 \tag{3}$$

4. 시간별 발전량을 예측하기 위한 알고리즘 개발 및 분석

4.1.1 태양광 발전소가 소재한 지역의 날씨 데이터 취득

시간대별로 발전량을 예측하기 위한 알고리즘을 개발하기 위해, 데이터는 태양광 발전소가 소재한 기지 A, B, C의 기상데이터를 1 시간 주기 단위로 추출하였다.

모든 태양광 발전소 사이트의 데이터는 15분마다 제공된다. 반면 날씨 데이터는 시간 단위로 제공되므로 발전소 평균 전력 및 평균 외부 온도에 대한 시간별 값을 얻기 위한 균등화 작업이 사전에 수행되었다.

날씨 데이터를 기반으로 시간 단위로 전력을 정확하게 예측하려면 평균 경사 태양 복사, 평균 수평 태양 복사 및 평균 외부 온도와 같은 특정 변수에 대한 데이터가 필요하다. 문제는 이러한 데이터를

<Table 5> Input variables for prediction hourly based power generation rate

Required Input Variables	Available Input Variables
<ul style="list-style-type: none"> • 평균 경사 태양 복사 • 평균 수평 태양 복사 • 평균 외부 온도 	<ul style="list-style-type: none"> • 날씨 (월, 일 및 시간) • 온도 • 바람의 방향 • 바람의 속도 • 습도

<Table 6> Analysis results of cross-correlation and RMSEP per predicted items


Prediction Item	Analytic Item	LM	SVM	ANN
Average Solar Radiation on a Tilted Surface	Cross-Correlation	0.50	0.499	0.797
	RMSEP	946	950	603
Average Solar Radiation on a Horizontal Surface	Cross-Correlation	0.52	0.52	0.82
	RMSEP	819	821	499
Accuracy of Power Generation Prediction	Cross-Correlation	0.96	0.96	0.97
	RMSEP	173	173	139

일기 예보에서는 제공하지 않는다는 것이다. 따라서 본 장에서는 가용한 데이터를 기반으로 상기 변수들을 예측하기 위한 모델을 개발하였다, 시간대별 전력생산량을 예측하기 위한 요구변수와 날씨 데이터로부터 가용한 입력변수들을 정리하면 표 5와 같다.

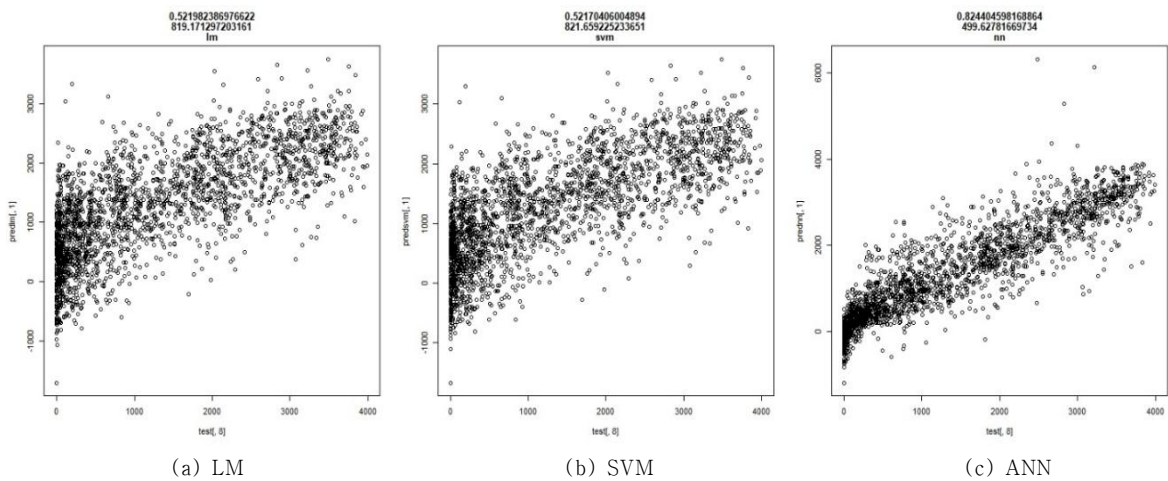
4.1.2 예측 모델의 적용

A. 평균 경사 태양 복사량 예측

예측 모델 개발을 위해 4장과 동일하게 선형 모델, SVM 및 ANN 의 세 가지 모델이 생성되었다. 이들 모델을 이용하여 먼저 평균 경사 태양 복사량 예측을 실시하였다. 그림에서와 같이 ANN의 상관도가 0.79로서 가장 높고, LM과 SVM의 경우 0.5 정도임을 알 수 있다. 또한 RMSEP 예측오차의 경우도 ANN 기법이 603 정도로 가장 낮게 분석되었다. 동일한 기법이 평균 수평 태양 복사량과 평균 외부온도 데이터 예측에도 적용되었다. 표 6은 상기 분석결과를 표로 보여주고 있다.



[Figure 7] Correlation between Measured and Predicted power output (applying average solar radiation on a horizontal surface)



[Figure 8] Correlation between Measured and Predicted power output (applying average solar radiation on a horizontal surface, tilted surface, and average ambient temperature)

그림 7은 평균 수평 태양 복사량 예측 결과를 적용한 발전량 예측결과이다. 그림에서와 같이 ANN 모델이 LM과 SVM에 비해 높은 상관도를 가짐을 알 수 있다

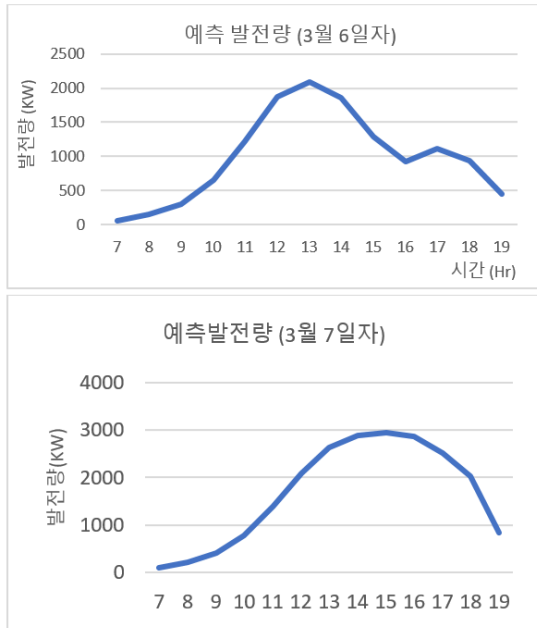
B. 태양광의 수평 및 수직 복사량 분석

ANN 기법은 태양광 패널의 평균 외부 온도와 평균 경사 태양 복사 및 평균 수평 태양 복사량 예측을 잘 수행하는 것으로 관측되었다. 이러한 결과를 바탕으로 발전량 예측을 실시한 결과는 그림 8과 같다.

4.1.3 시간대별 태양광 발전량 예측 결과

발전량데이터는 2019년 3월 9일과 7일 양일에 걸쳐 취득하고, 이를 날씨 데이터와 연동하여 최종적인 분석을 시간대 별로 수행하였다.

그림 9는 3월 6일과 7일 양일간 취득한 데이터를 이용한 발전량예측 결과를 보여주고 있다. 이 결과는 ANN 기법을 이용하여 수행하였으며, 결과와 전력 예측 (kW)은 날씨 데이터로부터 수행되었다.



[Figure 9] Hourly based power output prediction results (March 6th and 7th)

5. 결론 및 향후 연구 계획

태양광 발전은 일조시간과 대기 온도, 일조량, 습도 등에 따라 효율이 변동된다. 따라서 일기 예보 정보를 기반으로 발전량을 실시간 분석하고 예측할 수 있다면 전력 거래시장에서 높은 수익을 얻을 수 있을 것이다. 본 연구에서는 다양한 많은 정보를 동시에 처리하기 위해, 시스템 엔지니어링 방법론에 기반 한 빅데이터 관리 프로세스를 도입하였다. 구현 단계에서는 예측 식을 도출하는 두 가지 방법을 설정하고 시험하였다. 먼저 발전량만을 기상 정보와 운전 정보를 이용하여 분석하였고, 이를 통해 상관도는 0.9946, RMSEP 예측오차는 76.114로 약 5% 이내로 예측이 가능함을 입증하였다. 또한 시간대별 발전량 예측을 위해 태양광의 수직, 수평 복사량과 태양광 패널의 온도 정보를 추가하여 예측을 실시하였고, 상관도는 0.97, 예측오차는 139로서 약 10% 정도의 오차를 보이는 것으로 분석되었다. 시간대별 오차가 전체 예측 오차보다 큰 이유로는 태양광의 수직, 수평 복사량 정보가 제공되지 않아

이를 예측하는 과정에서 추가적인 오차가 산입된 것으로 판단되므로 향후 이러한 변수에 대한 측정 데이터를 기준으로 ANN 훈련이 이루어질 경우, 시간대별 예측 오차율도 낮출 수 있을 것으로 판단된다.

세 가지 기법 모두 발전량 예측을 99% 이상의 상관도를 가지고 예측할 수 있어 미래의 발전량을 5% 이내의 오차 이내로 예측 가능함을 알 수 있었다. 향후 더욱 많은 데이터를 이용하여 최적화 작업을 거친다면 제안 방법론이 실용적으로 활용 가능할 것으로 판단된다. 본 연구의 결과는 경쟁기술이 갖지 못한 가치를 지닌 새로운 비즈니스 모델[15]화 하는데 적극 활용할 수 있을 것으로 사료된다.

References

1. Mark A. Beyer, Douglas Laney, The importance of 'Big Data': A Definition, Gartner, 21 June 2012.
2. John Grantz, David Reinsel, "Extracting Value from Chaos", IDC IVIEW, 2011.
3. James Manyika & Michael Chui, "Big data: The next frontier for innovation, competition, and productivity", McKinsey Global Institute, 2011.
4. Alexander Kossiakoff, William N. Sweet, Sam Seymour, Steven M. Biemer, Systems Engineering Principles and Practice, John Wiley & Sons, 2011.
5. Jae-Gon Kim 외, Daily prediction of solar power generation based on weather forecast information in Korea, IET Renewable Power Generation 11(10), 2017.
6. SHARMA, Navin, 외 "Predicting Solar Generation from Weather Forecasts Using Machine Learning", IEEE International Conference on Smart Grid Communications, 2011.
7. Wikipedia, Solar power forecasting, https://en.wikipedia.org/wiki/Solar_power_forecasting

8. A. Saberian 외, "Modelling and Prediction of Photovoltaic Power Output Using Artificial Neural Networks", international Journal of Photoenergy, 2014.
9. INCOSE 시스템엔지니어링 핸드북-시스템 수명주기 프로세스 및 활동지침서 4판, INCOSE-한국시스템 엔지니어링협회.
10. <https://www.accuweather.com>
11. <https://ko.wikipedia.org/wiki/서포트벡터머신>
12. Cortes, C. and Vapnik, V. "Support-vector networks", Machine Learning, 1995.
13. Vapnik, V. (2000). "Section 5.6. Support Vector Machines-The nature of statistical learning theory", Springer-Verlag New York. ISBN 978-1-4419-3160-3.
14. Press, William H.; Teukolsky, Saul A.; Vetterling, William T.; Flannery, B. P. "Section 16.5. Support Vector Machines-Numerical Recipes: The Art of Scientific Computing 3판" Cambridge University Press. ISBN 978-0-521-88068-8.
15. 송치성, 4차 산업혁명과 지능화 사회에서 에너지 관리시스템 구축을 위한 정책적 제안과 플랫폼 구축, 한국산업기술진흥원, 2018.