

풍향과 풍속의 특징을 이용한 SVR기반 단기풍력발전량 예측

김 영 주*, 정 민 아*, 손 남 례^o

Forecasting of Short-term Wind Power Generation Based on SVR Using Characteristics of Wind Direction and Wind Speed

Yeong-ju Kim*, Min-a Jeong*, Nam-rye Son^o

요 약

본 논문은 풍력발전예측의 정확도 개선을 위하여 바람의 특성을 반영한 풍력발전량예측 방법을 제안한다. 제안한 방법은 크게 바람의 특성을 추출하는 부분과 발전량을 예측하는 부분으로 구성된다. 바람의 특성을 추출하는 부분은 발전량, 풍향과 풍속의 상관분석을 이용한다. 풍향과 풍속의 상관관계를 근거로 K-means 방법으로 클러스터링하여 특징 벡터를 추출한다. 예측하는 부분은 임의의 실수값을 예측 할 수 있도록 SVM을 일반화 한 SVR을 이용하여 기계학습을 한다. 기계학습은 바람의 특성을 반영한 제안한 방법과 바람의 특성을 반영하지 않은 기존방법을 비교 실험하였다. 또한, 제안한 방법의 정확도와 타당성을 검증하기 위하여 장소가 상이한 제주도 풍력발전단지 3지역에서 수집된 데이터를 사용하였다. 실험결과, 제안한 방법의 오차가 일반적인 풍력발전예측 오차보다 개선되었다.

Key Words : Wind Power Generation Forecasting, K-means Clustering, SVR, Extraction Feature Vector

ABSTRACT

In this paper, we propose a wind forecasting method that reflects wind characteristics to improve the accuracy of wind power prediction. The proposed method consists of extracting wind characteristics and predicting power generation. The part that extracts the characteristics of the wind uses correlation analysis of power generation amount, wind direction and wind speed. Based on the correlation between the wind direction and the wind speed, the feature vector is extracted by clustering using the K-means method. In the prediction part, machine learning is performed using the SVR that generalizes the SVM so that an arbitrary real value can be predicted. Machine learning was compared with the proposed method which reflects the characteristics of wind and the conventional method which does not reflect wind characteristics. To verify the accuracy and feasibility of the proposed method, we used the data collected from three different locations of Jeju Island wind farm. Experimental results show that the error of the proposed method is better than that of general wind power generation.

* First Author : Mokpo National University Department of Computer Engineering, xfile-7@daum.net, 정희원

^o Corresponding Author : Honam University Department of Information and Communication Engineering, nrson@honam.ac.kr, 정희원

* Mokpo National University Department of Computer Engineering, majung@mokpo.ac.kr, 정희원

논문번호 : KICS2017-01-030, Received January 31, 2017; Revised April 14, 2017; Accepted April 25, 2017

I. 서 론

최근 전 세계적으로 지구 온난화와 화석에너지 고갈 문제로 신재생에너지원에 대한 관심이 급속도로 높아지고 있다. 다양한 신재생에너지원 중 환경적 및 기술적 여건으로 가장 많은 관심을 받는 것 중 하나가 풍력에너지원이다^[1]. 풍력에너지원은 풍속 및 풍향 등 자연조건에 따라 출력이 변동되는 불확실성 특징을 지닌다. 즉 일반 발전원인 화력 또는 원자력 발전 방식과는 달리 발전 지점 및 발전량을 운영자가 제어할 수 없는 문제점을 가지고 있다. 이러한 특성 때문에 피크 수요 때의 에너지원으로서의 기여도가 기존 발전원들에 비해 떨어지게 된다. 또한 국내 경우와 같이 전력계통이 지역적으로 연계되어 있지 않고, 수요의 변화에 따른 전원규모를 국내에서 모두 확보해야 하는 상황인 경우, 풍력에너지원의 불확실성 문제는 중요하게 취급되어야 할 것으로 판단된다. 위와 같은 풍력에너지원의 단점과 국내 전력계통의 특성상 풍력에너지원의 예측은 매우 중요한 기술로 대두되고 있다^[2-5].

풍력발전출력예측에 사용되는 모델은 NWP(Numerical Weather Prediction) 방법, 통계적 방법, 인공지능 방법 같이 3가지로 구분할 수 있다^[6]. NWP 방법은 기상 데이터들과 풍력 발전기가 설치된 장소의 환경적 특징(온도, 습도, 지형 등)을 반영 한 수학적 모델링을 이용하여 장기 풍력에너지량을 예측하는데 주로 사용한다^[7]. NWP 방법의 단점은 많은 변수의 수학적 모델링으로 인해 예측 모델 구성이 난해하며, 과거 데이터의 양에 비례하여 예측의 정확성이 높아지기 때문에 많은 양의 데이터가 필요하다. 그로 인해 예측 모델의 수학적 구성이 매우 난해하며, 계산과정이 복잡하여 많은 계산량을 요구한다. 통계적 방법의 경우는 시계열 분석 모델인 ARIMA(Autoregressive Integrated Moving Average) 모델을 주로 사용한다^[8]. 세 번째 방법인 인공지능을 이용한 풍속 예측으로는 신경망네트워크(Neural Network)[9], 퍼지이론(Fuzzy Inference)[10], SVM(Support Vector Machine)^[11]를 많이 사용한다. 풍력에너지 예측의 중요성이 강조되는 이유는 전력계통에서 풍력발전기가 중앙수급발전기가 되었을 때 발전기 유지 보수, 발전기 기동정지 계획, 경제급전, 전력수급계획(발전기, 송전선로 등), 전력시장 입찰 등에 영향을 미치기 때문이다. 이런 이유로 풍력에너지 예측은 예측 시점에 따라 단기, 중기, 장기로 구분할 수 있다^[12]. 기존 풍력발예측모델에서 NWP는 장기 예측에 유리하고, 통계적 방법 및 인공지능 방법은 비교적 과거 데이터 양과 단순한 모델로

예측할 수 있으며, 주로 단기 예측에 적합하다. 하지만 통계적 방법인 ARIMA 모델은 시간이 흘러가면서 예측오차가 커지는 단점을 가지고 있고, 인공지능의 방법은 범용성에서 탁월한 성능을 보이지만 모형 인자 간의 인과관계를 설명할 수 없다는 단점이 있다. 또한, 기존 단기풍력발전단지 예측방법들은 바람의 특성을 고려하지 않은 단점을 가지고 있다.

따라서 본 논문에서는 풍력발전단지의 단기풍력발전량을 예측하기 위하여 바람의 특성인 풍향 및 풍속을 근거로 예측하는 방법을 제안한다. 제안한 방법을 검증하기 위하여 제주도 A, B, C 지역 풍력발전단지에서 수집된 데이터의 풍향, 풍속, 발전량을 이용하였고, 수치예측에서 최적의 성능을 보이는 기계학습 방법인 SVR을 사용하였다.

본 논문의 구성은 다음과 같다. 2장은 제안한 논문에 대한 관련연구로 제주도 지역의 풍향 및 풍속, 클러스터링 방법인 K-Means, SVR을 설명한다. 3장은 제안한 방법에 대하여 구체적으로 설명한다. 4장은 제안한 아이디어를 검증하기 위한 실험 및 결과이다. 마지막으로 5장에서는 결론 및 향후연구이다.

II. 관련연구

2.1 제주도의 풍향 및 풍속 특징

제주도의 평균풍향을 보면 제주 북부지역은 1923~2009년까지 주 풍계가 북에서 북서풍으로 나타났고, 주 풍속은 3.0~8.0m/s의 분포를 보였다. 제주 남부지역은 1962~2009년까지 주 풍계가 북동풍과 서남서풍이 우세한 것으로 나타났고, 주 풍속은 3.0~8.0m/s의 분포를 보였다. 제주 서부지역은 1988~2009년까지 주풍계가 북북서에서 북북동풍으로 나타났고, 주 풍속은 8.0~13.9m/s의 분포를 보였다. 제주 동부지역은 1973~2009년까지 주 풍계가 서북서에서 북북서풍으로 나타났고 주 풍속은 3.0~8.0m/s의 분포를 보였다^[13].

2.2 K-means Clustering

클러스터링 알고리즘은 데이터들의 유사성을 비교하여 비슷한 속성을 가지는 데이터들을 하나의 그룹으로 묶는 기법이며 계층적 클러스터링과 비계층적 클러스터링으로 나뉜다^[14]. k-means Clustering은 비계층적 클러스터링으로 n 개의 관측치를 k개의 클러스터로 분할하는 것을 목표로 하며, 각 관측치는 가장 가까운 평균을 갖는 클러스터에 속하며 클러스터의 프로토타입 역할을 한다. 식(1)은 k개로 클러스터 하

는 방법이다.

$$V = \sum_{i=1}^k \sum_{j \in S_i} |x_i - \mu_j| \quad (1)$$

x_i 는 n 개의 실 데이터이고, S_i 는 클러스터내의 집합이고, μ_j 는 S_i 의 점들의 평균이며 V 는 전체 분산이다. 알고리즘의 목표는 분산을 최소화하는 S_i 를 찾는 것이다.

2.3 Support Vector Regression

SVM(Support Vector Machine)은 기계 학습 분류 알고리즘의 하나로써 두 그룹을 분류하기 위하여 최적의 분리 경계면인 초평면(Hyperplane)을 제공한다^[11]. 또한, 비선형 분류는 주어진 데이터를 고차원 특징 공간으로 사상하는 작업이 필요한데, 이를 효율적으로 하기 위해 커널 트릭을 사용하며 이러한 커널 트릭은 커널 함수를 사용한다. 커널 함수의 대표적인 방법은 다항식 커널(Polynomial Kernel), 가우시안 커널(Gaussian Kernel), 시그모이드 커널(Sigmoid Kernel)이 있다. 최적화 식은 아래 식(2)과 같다. 식(2)에서, x 는 입력 벡터, y 는 출력벡터, w 는 계수 벡터, C 는 단위 비용(Unit Cost)이고, ξ_i 는 조건완화를 위한 여분(Slack)이다.

$$\begin{aligned} \min. & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \text{ w.r.t } w \text{ and } \xi_1, \dots, \xi_n \\ \text{s.t. } & 1) y_i - f(x) - \xi_i \leq \epsilon, \text{ if } y_i - f(x) \geq \epsilon, \\ & 2) y_i - f(x) + \xi_i \geq -\epsilon, \text{ if } y_i - f(x) \leq -\epsilon \end{aligned} \quad (2)$$

본 논문에서 단기풍력발전예측을 실험을 하기 위하여 SVM을 일반화한 SVR(Support Vector Regression)을 사용한다. SVR(ϵ -SVR)은 식(3)과 같이 임의의 실수 값을 높은 차원 공간으로 사상시킨 후, 최적화 기술을 적용하여 선형 회귀(linear regression)를 통해 최적의 초평면을 찾아 데이터를 예측하는 방법이다^[15].

$$\begin{aligned} \min. & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{s.t. } & y_i - \langle w, x_i \rangle - b \leq \epsilon + \xi_i \\ & \langle w, x_i \rangle + b - y_i \leq \epsilon + \xi_i^* \\ & \xi_i, \xi_i^* \geq 0 \end{aligned} \quad (3)$$

식(3)에서 b 는 바이어스, ξ_i, ξ_i^* 는 여분이며 나머지

는 식(2)과 같다.

III. 제안한 방법

본 논문에서 제안한 방법의 순서도는 그림 (1)과 같고, 순서도의 내용은 다음과 같다. 첫째, 풍력발전단지에서 생성된 발전량, 풍속, 풍향 데이터 단위가 각각 다르므로 데이터 전처리(Data Pre-Processing)과정이 필요하다. 둘째, 풍향과 풍속의 특징벡터를 추출하기 위한 상관분석과 클러스터링을 수행하는 단계이다. 상관분석은 발전량, 풍향, 풍속을 피어슨 상관분석과 스피어만 상관분석을 수행하고, 클러스터링은 풍향과 풍속을 k-means 클러스터링을 이용한다. 셋째, 단기풍력발전량을 예측하기 위하여 제주도 A, B, C지역 풍력발전단지의 데이터를 학습데이터와 시험데이터로 분할한다. 넷째, 학습데이터에 대하여 SVR을 수행하여 단기풍력발전량 예측 모델을 유도한다. 다섯째, 단기풍력발전량 예측 모델은 시험 데이터에 적용하여 최종적으로 단기풍력발전량을 예측한다. 예측된 단기풍력발전량은 기존방법으로 예측한 발전량과 비교 검증한다.




그림 1. 제안한 방법과 기존방법의 순서도
Fig. 1. Flowchart of proposed method and conventional method

3.1 데이터 전처리

제주도 A, B, C 지역 풍력발전단지에서 생성된 발전량, 풍속, 풍향 데이터 단위는 각각 다르므로 각각의 데이터를 [0.0, 1.0] 범위 내에 위치하도록 정규화가 필요하다. 본 논문에서 사용하는 정규화 방법은 최소-최대 정규화(Min-Max Normalization) 방법이다^[16]. 이 방법은 식(4)와 같이 원 데이터에 대해 선형 변

환 하는 것으로 원 데이터 값을 주어진 범위 안에서 그대로 유지된다.

$$\nu'_i = \frac{\nu_i - \min_A}{\max_A - \min_A} (w_{\max_A} - w_{\min_A}) + w_{\min_A} \quad (4)$$

식(4)에서 속성A에 대한 최소값과 최대값은 \min_A 와 \max_A 일 때, 최소-최대 정규화는 A의 값 ν_i 를 식(4)에 적용하여 범위 $[w_{\min_A}, w_{\max_A}]$ 에서 값 ν'_i 로 변환한다.

3.2 특징벡터 추출

3.2.1 상관분석

그림 (2)는 제주도 A지역 풍력발전단지의 발전량(Wind Power), 풍속(Wind Speed), 풍향(Wind Direction) 관계를 산점도로 표현하였다.




그림 2. 발전량, 풍속, 풍향의 산점도
Fig. 2. Scatter plot of power generation, wind speed, and wind direction

표 1. 제주도 A지역의 발전량, 풍향, 풍속의 상관분석
Table 1. Correlation analysis of wind power generation, wind direction and wind speed in A region of Jeju Island.

Wind power plant	Variable	Pearson correlation coefficient	Spearman correlation coefficient
A	Wind power generation, wind direction	0.5	0.994
	Wind power generation, wind speed	0.9	0.994
	Wind direction, wind speed	0.45	0.999

그림 (2)에서 발전량과 풍속은 양의 상관관계가 있다. 즉, 풍속이 증가하면 발전량이 증가하나, 어느 풍속이 되면 발전량은 더 이상 증가하지 않고 일정해진다. 반면, 풍속과 풍향은 일정한 그룹이 형성되는 것이 나타난다. 이는 풍속과 풍향이 비선형의 상관관계가 있다는 것이다.

표 (1)은 발전량, 풍향, 풍속의 상관분석을 나타낸 것이다. 발전량과 풍속은 선형관계를 나타내는 피어슨 상관계수가 0.9로 강한 양의 상관관계를 보이고 풍향과 풍속은 비선형관계를 나타내는 스피어만 상관계수가 0.999로 강한 양의 비선형관계를 나타냈다. 피어슨 상관계수는 두 변수 간의 선형적인 상관관계를 측정하며 식(5)와 같이 정의된다.

$$\rho(X, Y) = \frac{cov(X, Y)}{\sigma_x \sigma_y} \quad (5)$$

식(5)에서 $cov(X, Y)$ 는 X, Y 의 공분산, σ_x, σ_y 는 X, Y 의 표준편차이다. 스피어만 상관계수는 비선형 관계의 연관성을 파악할 수 있다는 장점이 있으며 식(6)과 같이 정의된다.

$$\rho = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2} \sqrt{\sum_i (y_i - \bar{y})^2}} \quad (6)$$

식(6)에서 x_i 는 변수 x 에서 i 번째 데이터의 순위, y_i 는 변수 y 에서 i 번째 데이터의 순위이고 \bar{x}, \bar{y} 는 각각 x, y 의 평균이다. 이러한 풍향과 풍속의 비선형관계를 풍력발전량을 예측하는데 적용하면 풍력발전예측

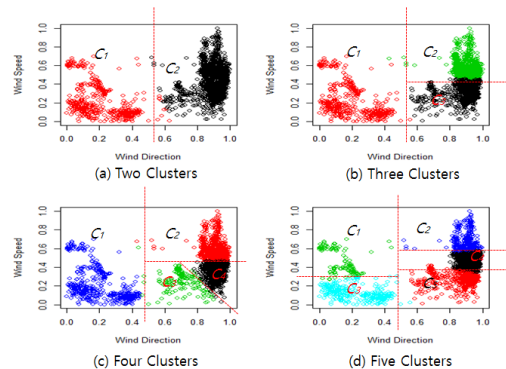


그림 3. 풍속과 풍향을 이용한 클러스터링
Fig. 3. Clustering using wind speed and wind direction

표 2. 제주도 A지역의 풍향과 풍속
Table 2. Wind direction and wind speed in A region of Jeju Island

Group	Wind direction	Wind speed
1	308.85	12.92
2	319.90	8.70
3	297.41	5.02
4	70.13	4.09

의 정확도가 향상될 것이다.

3.2.2 K-Means Clustering

그림 (3)은 제주도 A지역의 풍력발전단지를 풍속과 풍향을 이용한 후, 클러스터링 결과이다. 그림3(a)는 클러스터 2개, 그림3(b)는 클러스터 3개, 그림3(c)는 클러스터 4개, 그림3(d)는 클러스터 5개이다. 즉, 같은 특성을 지닌 풍속과 풍향은 같은 클러스터로 형성된다. 일정한 시점에서 풍속에 따른 풍향이 존재한다는 것이다.

제주도 A지역 풍력발전단지의 2014년 1월의 바람은 표(2)와 같이 그룹1은 서북서와 북서사이 풍, 그룹2은 북서풍, 그룹3은 서북서풍, 그룹4은 동북동풍의 풍속과 풍향의 특성이 나타났다. 다른 풍향에서는 풍속이 나타나지 않았다.

A지역의 클러스터에 따른 풍향은 그림4(a)와 같다. 만약 풍향과 풍속 간의 관계를 무시하고 풍향을 그림4(b)와 같이 0°에서 359°로 총 360개로 설정하여 다변수를 고려한 SVR을 수행한다면 풍향이 발산하여 단기풍력발전량을 정확히 예측할 수 없다.

따라서, 본 논문에서 제안한 방법은 제주도 A지역의 풍력발전단지의 풍향 및 풍속의 특징을 가지고 클러스터링 후, SVR을 수행한다면 효율적인 단기풍력발전량을 예측할 수 있다.




그림 4. 풍향의 각도
Fig. 4. Angle of Wind Direction

3.3 데이터분할: 학습데이터 및 시험 데이터

본 논문에서 단기풍력발전량을 예측하기 위하여 제주도 A, B, C지역 풍력발전단지에서 수집된 데이터를 기반으로 학습데이터 및 시험데이터를 구분하여 실험하였다. 이때 학습 데이터 및 시험 데이터는 모두 정규화된 데이터이고, 표(3)과 같이 각 지역별로 수집기간, 수집시간, 학습데이터, 시험데이터, 총 데이터를 보여준다. 또한, 매 10분 단위로 수집되었기 때문에 A지역은 7.5일, B지역은 3일, C지역은 5일을 예측하였다. 본 논문에서 제안한 방법의 실험은 평균적으로 5일 동안의 단기풍력발전량을 예측하였다.

표 3. 각 지역별 수집기간, 수집시간, 학습데이터, 시험데이터, 총데이터
Table 3. The Collection period, collection time, training data and testing data of each region

Region	Collection period	Collection time	Training data	Testing data	Total data
A	January 11-25, 2014	Every 10 minutes	1080 (50%)	1080 (50%)	2160
B	January 11-20, 2014	Every 10 minutes	1008 (70%)	432 (30%)	1440
C	January 11-25, 2014	Every 10 minutes	1440 (67%)	720 (33%)	2160

3.4 nu-SVR

ϵ -SVR의 문제점은 학습하기 전에 ϵ 값을 정해줘야 하는 단점을 가지고 있다. 이러한 단점을 해결하기 위해 nu-SVR은 ϵ 값을 최적화 문제의 변수들 중 하나로 인식하고, 다른 변수들과 함께 가능한 가장 작은 ϵ 값을 갖도록 최적화 문제에 포함시켜 표현함으로써 최적화 문제를 해결함과 동시에 최적의 ϵ 값을 구한다. 또한, nu-SVR은 식(7)과 같이 ν 값의 변화에 따라 지지 벡터(Support Vector)의 개수를 조절할 수 있는 장점이 있다¹⁵⁾.

$$\begin{aligned}
 \min. & \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^* + \nu \epsilon) \\
 \text{s.t.} & \quad y_i - (\langle w, \phi(x_i) \rangle + b) \leq \epsilon + \xi_i \\
 & \quad (\langle w, \phi(x_i) \rangle + b) - y_i \leq \epsilon + \xi_i^* \\
 & \quad \xi_i, \xi_i^*, \epsilon \geq 0, i = 1, \dots, m
 \end{aligned}
 \tag{7}$$

본 논문에서는 발전량, 풍향, 풍속의 다변수를 이용하여 단기풍력발전예측을 위해서 nu-SVR을 적용한다. nu-SVR 모델링을 최적화하기 위하여 Epsilon은

0.1, Cost는 1을 사용하였다. 이때 사용한 커널은 식 (8)과 같이 가우시안 커널이다^[17]. 가우시안 커널은 무한 차원으로 데이터를 옮긴 뒤, 그곳에서 내적을 계산한 것과 같은 결과를 반환한다.

$$K(x,y)=\exp(-\gamma \|x-y\|^2) \quad (8)$$

3.5 제안한 방법과 기존방법의 비교

본 논문에서 기존방법은 그림(1)에서 보는 바와 같이 발전량, 풍향, 풍속의 특징을 고려하지 않고 단지 발전량, 풍향, 풍속의 데이터를 이용해서 SVR을 수행한 것이다. 반면, 제안한 방법은 발전량, 풍향, 풍속 각각의 변수간의 상관분석을 수행한 후 바람의 특성을 K-means Clustering을 이용하여 특징벡터를 추출한 후 추출된 특징벡터를 반영한 발전량, 풍속, 풍향의 데이터를 이용해서 SVR을 수행한 것이다.

IV. 실험 및 결과

4.1 실험환경

본 논문에서 제안한 방법을 검증하기 위하여 실험 환경은 Intel i7-4770 3.40GHz CPU, 4GB RAM이 장착된 PC에서 수행하였으며, 테스트 운영체제는 Windows7(32bit)이며 실험 프로그램은 R i386 3.2.2 와 R-Studio v8.0이다. 마지막으로 풍력발전량예측 오차를 검증하기 위하여 식(9)와 같이 RMSE(Root Mean Square Error)를 사용하였다^[18].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - \hat{p}_i)^2} \quad (9)$$

식(6)에서 p_i 와 \hat{p}_i 은 각각 발전량 실측값과 예측값을 의미하고, n 은 훈련데이터의 개수이다.

4.2 실험 결과

표(4)는 제주도 A, B, C지역의 단기풍력발전예측량을 비교한 것이다. 또한, 제안한 방법에서 최종적으로 사용한 클러스터는 A지역은 4개, B지역은 3개, C지역은 2개이다. 이와 같은 이유는 A, B, C지역의 위치가 달라 각각 상이한 기상조건으로 클러스터가 다양하게 형성되었다. 결과적으로 제안한 방법은 바람의 특성인 풍향과 풍속을 고려하지 않은 기존 방법에 비하여 오차가 작게 나타났다.

제안한 방법의 각 지역별 평균오차를 보면 제주도 A지역의 제안한 방법은 4.13, 기존 방법은 8.78로

표 4. 제주도 A, B, C지역의 단기풍력발전량 예측 비교
Table 4. Comparison of Short-term Wind Power Generation Forecasts in A, B, and C Region of Jeju Island

Region	Conventional method (A)	Proposed method (B)	Difference (A-B)
A	8.78	4.13	4.48
B	2.79	1.57	1.22
C	4.57	3.57	1

4.48의 차를 보이고, 제주도 B지역의 제안한 방법은 1.57이고, 기존 방법은 2.79이어서 제안한 방법이 기존 방법에 비하여 1.22의 차가 적었다. 마지막으로 제주도 C지역의 제안한 방법은 3.57이고, 기존 방법은 4.67이어서 제안한 방법이 기존 방법에 비하여 1만큼 오차가 적었다. 제주지역의 기존방법들은 평균적으로 5.38이상 오차를 초과하였다. 하지만 제안한 방법은 평균적으로 2.23이상 오차를 초과하지 않아서 기존 방법에 비하여 상당히 오차를 개선하였다.

그림 (5) 및 그림 (6)은 각각 시험데이터 1080개 및 432개를 훈련한 제주도 A지역 및 B지역의 단기풍력 발전예측량에 대하여 '관측된 발전량(Observed Wind Power)', '기존 방법(Conventional Method)', '제안한




그림 5. 제주도 A지역의 발전량 실측값, 기존 방법 및 제안한 방법 비교
Fig. 5. Comparison of Actual Generation Value, Conventional Method, and Proposed Method of A Region in Jeju Island




그림 6. 제주도 B지역의 발전량 실측값, 기존 방법 및 제안한 방법 비교
Fig. 6. Comparison of Actual Generation Value, Conventional Method, and Proposed Method of B Region in Jeju Island




그림 7. 제주도 C지역의 발전량 실측값, 기존 방법 및 제안한 방법 비교
 Fig. 7. Comparison of Actual Generation Value, Conventional Method, and Proposed Method of C Region in Jeju Island

방법(Proposed Method)’에 대한 비교 그래프이다. 제안한 방법은 기존 방법에 비하여 관측된 발전량에 거의 유사하였다. 특히, 관측된 발전량이 일정한 시간동안 변동이 없을 때 기존 방법은 관측된 발전량에 비하여 상당한 오차를 보였다. 하지만 제안한 방법은 개선되었음을 그래프에서 확인 할 수 있다. 그림(7)은 시험데이터 720개를 훈련한 제주도 C지역의 단기풍력발전예측량에 대한 비교 그래프이다. 관측된 발전량이 급변하는 경우, 기존방법은 관측된 발전량에 비하여 오차가 크거나 작게 예측하였다. 그러나 제안한 방법은 관측된 발전량의 급변함과 관계없이 거의 유사하였다.

V. 결론 및 향후연구

본 논문에서 제안한 방법은 인공지능의 단점인 풍력에너지원의 다변수간의 인과관계(풍향, 풍속, 발전량 등) 특성을 파악하여 다변량 분석에 효율적인 SVR 방법을 적용하는 방법을 제안한다. 제안한 방법은 풍력발전기가 설치된 장소의 기상과 지형의 특성에 적합한 단기풍력발전량 예측 시스템을 구축하여 실용화하고, 이를 통해 국내 전기에너지생산 비용 절감 효과를 기대할 수 있다. 향후 연구는 풍력발전량 예측의 정확도 개선을 위한 풍향의 전처리와 군집화 방법 그리고 중장기 풍력발전량을 예측하는 실험을 진행할 것이다.

References

[1] A. S. Kim, H. S. Han, K. Y. Bae, and D. K. Sung, "Wind power forecasting based support vector machine for a large-scale wind farm in jeju island," in *Proc. KICS Int. Conf.*

Commun., pp. 11-12, Kangwon, Korea, Jan. 2016.

[2] A. M. Foley, P. G. Leahy, and E. J. McKeogh, "Wind power forecasting & prediction method," *IEEE, 9th Int. Conf. Environ. and Electrical Eng.*, pp. 16-19, May 2010.

[3] I. Y. Seo, B. N. Ha, S. O. Kim, W. N. Koong, D. W. Seo, and S. J. Kim, "Short term wind power prediction using wavelet transform and ARIMA," *J. Energy and Power Eng.*, pp. 1786-1790, Jun. 2012.

[4] K. Parks and Y. H. Wan, *Wind energy forecasting : A collaboration of the national center for atmospheric research(NCAR) and xcel energy*, NREL/SR-5500-52233, Oct. 2011.

[5] Y. Y. Hong, T. H. Yu, and C. Y. Liu, "Hour-Ahead wind speed and power forecasting using empirical mode decomposition," *Energies*, vol. 6, no. 12, pp. 6137-6152, Jun. 2013.

[6] G. Sideratos and N. Hatzigiorgiou, "An advanced statistical method for wind power forecasting," *IEEE Trans. Power Syst.*, vol. 22, no. 1, pp. 258-265, Feb. 2007.

[7] M. Negnevitsky and C. Potter, "Innovative short-term wind generation prediction techniques," *IEEE Power Syst. Conf. and Exposition*, pp. 60-65, 2006.

[8] T. El-Fouly, E. El-Saadany, and M. Salama, "Grey predictor for wind energy conversion systems output power prediction," *IEEE Trans. Power Syst.*, vol. 21, no. 3, pp. 1450-1452. Aug. 2006.

[9] J. Palomares-Salas, J. Rosa, J. Ramiro, J. Melgar, A. agüera, and A. Moreno, "ARIMA vs. Neural networks for wind speed forecasting," *CIMSA 2009 - Int. Conf. Computational Intell. for Measurement Syst. and Appl.*, pp. 129-133, 2009.

[10] I. Damousis, M. Alexiadis, J. Theocharis, and P. Dokopoulos, "A fuzzy model for wind speed prediction and power generation in wind parks using spatial correlation," *IEEE Trans. Energy Conversion*, vol. 19, no. 2, pp. 352-

361, Jul. 2008.

- [11] M. G. Choi, H. G. Lee, and S. C. Lee, "Evil-twin detection scheme using SVM with multi-factors," *J. KICS*, vol. 40, no. 2, pp. 334-348, Feb. 2015.
- [12] K. Kim, Y. Park, J. Park, K. Ko, and J. Huh, "Feasibility study on wind power forecasting using MOS forecasting result of KMA," *JKSES*, vol. 30, no. 2, Feb. 2010.
- [13] Y. Ho. Park, K. B. Kim, S. Y. Her, Y. M. Lee, and J. C. Huh, "A study on the wind data analysis and wind speed forecasting in Jeju area," *J. Korean Solar Energy Soc.*, vol. 30, no. 6, 2010.
- [14] D. H. Shin, K. K. An, S. C. Choi, and H. K. Choi, "Malicious traffic detection using K-means," *J. KICS*, vol. 41, no. 2, pp. 277-284, Feb. 2016.
- [15] Y. I. Kim, H. Y. Jo, and Y. J. Park, "A method of nu-SVR learning with a set of basis functions," *KIIS*, vol. 13, no. 3, pp. 316-321, Jun. 2003.
- [16] J. Han and M. Kamber, *Data Mining Concepts and Techniques*, p. 172, 2006.
- [17] C. G. Park, "Prediction of software development cost using support vector regression," *The Korean Operations Res. and Management Sci. Soc.*, vol. 23, no. 2, pp. 75-91, Nov. 2006.
- [18] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int. J. Forecasting*, vol. 22, no. 4, pp. 679-688, 2006.

김 영 주 (Yeong-ju Kim)



2005년 2월: 조선대학교 컴퓨터통계학 이학사
 2008년 2월: 목포대학교 정보·컴퓨터 교육학석사
 2017년 2월: 목포대학교 컴퓨터공학 공학박사
 <관심분야> 데이터베이스/데이터마이닝, 풍력발전예측, 시계열분석, 선박안전운항, 무선센서네트워크, 교육데이터마이닝 등

정 민 아 (Min-a Jeong)



1992년 2월: 전남대학교 이학사
 1994년 2월: 전남대학교 이학석사
 2002년 2월: 전남대학교 이학박사
 2002년 4월~2003년 2월: 광주과학기술원정보통신공학과 Post-Doc

2003년 4월~2005년 2월: 전남대학교 전자통신기술연구소 Post-Doc
 2011년 9월~2013년 2월: Cleveland Clinic Research
 2005년 3월~현재: 목포대학교 컴퓨터공학과 부교수
 <관심분야> 데이터베이스/데이터마이닝, 생체인식시스템, 무선통신응용분야, 임베디드시스템

손 남 레 (Nam-rye Son)



1996년 2월: 호남대학교 전산통계학과 학사
 1999년 2월: 전남대학교 전산통계학과 석사
 2005년 2월: 전남대학교 전산학과 박사
 2007년~2009년: 호남대학교

인터넷소프트웨어학과 전임강사
 2009년~2010년: 목포대학교 정보산업연구소 전임연구교수
 2011년~2017년: 한국전자통신연구원 기업지원선임연구원
 2017년~현재: 호남대학교 정보통신공학과 조교수
 <관심분야> 빅데이터분석솔루션, IoT, 영상통신, 통합관제센터, 전력IT 등