

A study on short-term wind power forecasting using time series models

Soo-Hyun Park^a · Sahm Kim^{a,1}

^aDepartment of Applied Statistics, Chung-Ang University

(Received September 2, 2016; Revised October 12, 2016; Accepted October 30, 2016)

Abstract

The wind energy industry and wind power generation have increased; consequently, the stable supply of the wind power has become an important issue. It is important to accurately predict the wind power with short-term basis in order to make a reliable planning for the power supply and demand of wind power. In this paper, we first analyzed the speed, power and the directions of the wind. The neural network and the time series models (ARMA, ARMAX, ARMA-GARCH, Holt Winters) for wind power generation forecasting were compared based on mean absolute error (MAE). For one to three hour-ahead forecast, ARMA-GARCH model was outperformed, and the neural network method showed a better performance in the six hour-ahead forecast.

Keywords: wind power, neural network, ARMAX, ARMA GARCH, Holt Winters

1. 서론

석탄, 석유 등 지하자원의 매장량의 한계와 환경 보호의 중요성이 대두되면서 신재생에너지 활용 및 발전에 대하여 전 세계의 관심이 집중되고 있다. 신재생에너지란, 신에너지와 재생에너지를 말한다. 산업통상자원부 신·재생에너지센터에서 발행한 “2014 신·재생에너지 백서”의 「신에너지 및 재생에너지 개발·이용·보급촉진법」에 따르면 ‘신에너지’란, 기존의 화석연료를 변환시켜 이용하거나 수소·산소 등의 화학 반응을 통하여 전기 또는 열을 이용하는 에너지로서 수소에너지, 연료전지, 석탄을 액화·가스화한 에너지 및 중질잔사유(重質殘渣油)를 가스화한 에너지를 말한다. ‘재생에너지’란, 햇빛·물·지열(地熱)·강수(降水)·생물유기체 등을 포함하는 재생 가능한 에너지를 변환시켜 이용하는 에너지로서 태양, 풍력, 수력, 해양에너지, 지열에너지, 생물자원을 변환시켜 이용하는 바이오에너지, 폐기물에너지를 말한다.

국내 신재생에너지 산업 중 태양에너지와 풍력에너지 발전이 활발히 이루어지고 있다. 이 중 풍력에너지에 초점을 맞추고자 한다. 풍력은 재생에너지의 일종으로 자원이 풍부하고, 대기가 사라지지 않는 한 끊임없이 재생되며, 광범위한 지역에 분포되어 있고, 깨끗하며, 또한 운전 중 온실가스의 배출이 없다는 점에서 화석에너지 고갈 시에 대비한 유망한 대체 에너지원으로서 각광받는 에너지이다. 풍

This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (NRF-2016R1D1A1B01014954).

¹Corresponding author: Department of Applied Statistics, Chung-Ang University, 84, Heukseok-ro, Dongjak-gu, Seoul 06974, Korea. E-mail: sahm@cau.ac.kr

력발전이란, 바람에너지를 풍력터빈(wind turbine) 등의 장치를 이용하여 기계적 에너지로 변환시키고, 이 에너지를 이용하여 발전기를 돌려 전기를 생산하는 것이다. 국내 풍력발전의 경우, 단지 및 발전기 설치 수가 증가하고 있고, 발전 규모의 증가하는 등 꾸준히 성장하고 있다. 한국풍력산업협회(<http://www.kweia.or.kr>)에서 공개한 자료에 따르면, 2014년 기준 지역별 풍력발전 이용률의 평균은 약 17.07%이다. 특히, 경상북도의 경우 풍력발전 이용률이 27.07%로 가장 높다. 이처럼 풍력발전 의존율이 높아질수록 안정적인 공급이 중요해질 것이다. 또한, 풍력발전은 바람의 영향으로 변동성이 크기 때문에 안정적인 전력수급계획을 세우기 위하여 풍력발전량 예측이 점점 중요해지고 있다.

풍력발전량 예측을 위하여 국내·외에서 다양한 방법들이 시도되고 있다. 국외 연구의 경우, Brown 등 (1984)은 풍속과 풍력을 시뮬레이션하고 예측하는 방법으로 autoregressive process를 활용하였다. Tol (1997)은 일별 풍속 측정 시 AR-GARCH model을 이용하였는데 유사한 추세를 예측하였다. Torres 등 (2005)은 ARMA model을 활용하였고, Hill 등 (2012)은 풍속이 전력시스템에 미치는 영향을 연구하기 위해 VAR을 활용하였다. Alexiadis 등 (1998), Quan 등 (2014), Chitsaz 등 (2015) neural network에 기반한 모형을 활용한 풍력 예측이 꾸준히 시도되었다.

국내 연구의 경우, 산업 초기에 잠재적인 풍력자원을 예측하기 위하여 Byun 등 (2005)은 덴마크 RISØ 연구소의 wind atlas analysis and application program(WAsP)을 이용하였다. 그 후 Ryu 등 (2009)은 풍속과 풍력발전의 상관관계를 통해 발전량 예측하였고, Shin 등 (2011)은 support vector regression을 활용하였다. Hwang 등 (2012)과 Park 등 (2012)은 power ramp rate를 고려하여 각각 다층 신경망, adaptive neuro-fuzzy inference system(ANFIS)을 통해 발전량을 예측하였다. 또한 Lee 등 (2013)은 ARMA와 신경망 모형의 예측 정확도를 비교하였다. 사실상 국내의 경우 풍력발전량을 예측하는데 있어서 시계열 분석보다는 데이터마이닝 기법을 더 많이 활용하고 있으며, 국내 상황에 적합한 시계열 예측 모형이 필요한 시점이다. 본 논문에서는 강원도에 설치된 풍력발전기로부터 생산된 시간별 풍력발전량과 기상청에서 수집된 풍속, 풍향 데이터를 활용하여 시계열 모형을 연구하고 모형별 단기 예측 성능을 비교하고자 한다.

다음 2장에서는 풍력발전량을 예측을 위한 신경망 모형과 시계열 모형에 대하여 소개한다. 3장에서는 활용된 풍력발전 데이터, 풍향과 풍속 데이터에 대하여 설명하고 그 분석 결과에 대하여 논할 것이다. 4장에서는 결론과 향후 연구 방향에 대하여 제안할 것이다.

2. 풍력발전량 예측 모형

풍력발전량 예측을 위한 기존 연구들에서 데이터마이닝 기법인 신경망 모형(neural network model)의 빈도가 높았다. 본 연구에서는 신경망 모형과 시계열 모형을 비교하고 더 나은 모형을 제시하고자 한다.

2.1. 신경망 모형

신경망 모형(neural network model)은 사람의 두뇌가 의사 결정하는 형태를 모방하여 여러 개의 노드(node)를 네트워크로 연결하는 모형이다. 본 논문에서는 다층신경망(multilayer neural network)를 이용하였으며 이는 Figure 2.1과 같이 입력 노드로 이루어진 입력층(input layer)과 입력층의 노드들을 합성하는 중간노드들의 집합인 은닉층(hidden layer) 그리고 은닉층의 노드들을 합성하는 출력층(output layer)으로 이루어져 있다.

2.2. ARMA 모형

Auto-regressive moving-average model(ARMA) 모형은 auto-regressive(AR) 모형과 moving-average




Figure 2.1. Multilayer neural network.

(MA) 모형을 동시에 포함하는 확률과정이다. 평균이 μ 이고 차수가 p, q 인 ARMA(p, q) 모형은 식 (2.1)과 같이 표현된다.

$$\phi(B)(Y_t - \mu) = \theta(B)\epsilon_t, \quad (2.1)$$

$$\text{where } \phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p,$$

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q.$$

이 때, $\phi(B)$ 는 AR에 관한 다항식이며, $\theta(B)$ 는 MA에 관한 다항식이고 B 는 후진연산자(backward shift operator)이다. Y_t 는 t 시점($t = 1, 2, \dots, T$)에서의 관측된 값이며 p, q 는 정수이다. ϵ_t 는 평균은 0, 분산은 일정한 백색잡음과정(white noise process)이다.

2.3. ARMAX 모형

Auto-regressive moving-average model with exogenous variables(ARMAX) 모형은 ARMA 모형에 외생변수를 추가한 모형이다. 평균이 μ 이고 ARMA의 차수가 p, q 일 때 외생변수 x_{it} 가 k 개인 경우 ARMAX(p, q)모형은 식 (2.2)과 같다.

$$\phi(B)(Y_t - \mu) = \theta(B)\epsilon_t + \sum_{i=1}^k \gamma_i x_{it}, \quad (2.2)$$

$$\text{where } \phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p,$$

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q.$$

이 때, $\phi(B)$ 는 AR에 관한 다항식이며, $\theta(B)$ 는 MA에 관한 다항식이고 B 는 후진연산자(backward shift operator)이다. Y_t 는 t 시점($t = 1, 2, \dots, T$)에서의 관측된 값이며 p, q 는 정수이다. ϵ_t 는 평균은 0, 분산은 일정한 백색잡음과정(white noise process)이다. 그리고 γ_i 는 외생변수 x_{it} 의 계수이다. 본 논문에서는 외생변수로 풍향을 고려하였다.

2.4. ARMA-GARCH 모형

ARMA-GARCH 모형은 평균 모형이 ARMA이고, 분산 모형이 GARCH인 경우이다. 기존의 ARMA는 등분산을 가정하고 있다. 하지만 등분산이 아닌 이분산성의 경우를 고려하기 위하여 Engle (1982)은 autoregressive conditionally heteroscedastic(ARCH) 모형을 제안하였는데, 현재 분산이 과거 분산의 영향을 받는 모형으로 확장하여 일반화한 generalized autoregressive conditionally heteroscedastic(GARCH) 모형을 Bollerslev (1986)이 제안하였다. 이를 고려한 것이다. ARMA(p, q)-GARCH(r, m)는 ARMA의 차수가 p, q 이고 GARCH의 차수가 r, m 인 것을 말하며, 식 (2.3)과 같이 정의된다.

$$\begin{aligned}\phi(B)(Y_t - \mu) &= \theta(B)\epsilon_t, \\ \epsilon_t &= \sqrt{h_t}e_t, \\ h_t &= \alpha_0 + \sum_{i=1}^m \alpha_i \epsilon_{t-i}^2 + \sum_{i=1}^r \beta_i h_{t-i}.\end{aligned}\quad (2.3)$$

이 때, $\phi(B)$ 는 AR에 관한 다항식으로 $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ 이며, $\theta(B)$ 는 MA에 관한 다항식으로 $\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ 이다. B 는 후진연산자(backward shift operator)이며, Y_t 는 t 시점($t = 1, 2, \dots, T$)에서의 관측된 값이다. $e_t \sim WN(0, \sigma^2)$ 이고, GARCH의 경우 모수들이 음이 아니어야 하는 비음조건(non-negative condition, $\alpha_0 > 0, \alpha_i \geq 0, \beta_i \geq 0$)을 만족해야 한다.

2.5. Holt Winters 모형

Winters (1960)가 제안한 Holt Winters 지수평활법은 계절성까지 고려할 수 있는 지수평활방법으로 가법(additive) 모형은 $t + h$ 시점에서 식 (2.4)와 같이 표현된다.

$$Y_{t+h} = L_t + T_t \times h + S_{t+h-s}, \quad (2.4)$$

여기서 Y_t 는 t 시점($t = 1, 2, \dots, T$)에서의 관측된 값을 의미한다. L_t 는 t 시점에서의 평활수준(level) 성분을 나타내며, T_t 는 t 시점에서의 추세(trend) 성분, S_t 는 t 시점에서의 계절(seasonality) 성분을 의미한다. 각 성분은 식 (2.5)와 같이 정의된다.

$$\begin{aligned}L_t &= \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}), \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, \\ S_t &= \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}.\end{aligned}\quad (2.5)$$

이 때, α 는 수준에 대한 모수, β 는 추세에 대한 모수, γ 는 계절에 대한 모수, s 는 계절 주기이다.

3. 데이터 및 분석 결과

3.1. 데이터 소개

본 연구에서 사용된 풍력발전 데이터는 강원도청에서 제공받았으며, 평창 횡계리에 설치된 대관령 2풍력(2MW 1기)의 풍력발전 데이터이다. 2015년 10월 1일부터 2015년 12월 15일까지 1,824개의 시간별 데이터를 훈련용 데이터(training data)로 모형 적합에 사용하였다. 그리고 2015년 12월 16일부터 22일까지 7일의 168개 데이터를 테스트 데이터(test data)로 모형의 성능을 평가하는데 활용하였다.

Figure 3.1에서 보이는 바와 같이 원 데이터는 분산이 일정하다고 말할 수 없으며 항상 양수이지만 갑작스런 돌풍과 같은 이유로 운영을 하지 않는 경우가 존재하여 값이 '0'인 데이터도 포함하고 있다. 따




Figure 3.1. Time plot for original wind power generation data.




Figure 3.2. Time plot for Box-Cox transformed wind power generation data.

라서 분산 안정화 등의 이유로 Box-Cox 변환을 하였고 Figure 3.2와 같다. 자료에서의 '0'값을 보정하기 위하여 자료에 0.25를 더하였다. 훈련 데이터에서의 최적 λ 인 0.243를 사용하여 보정하였으며, 변환 후 분산이 비교적 안정화된 것을 확인 할 수 있다. 모형 평가 시 Box-Cox 변환 된 값들을 원 수치로 변환하여 사용하였다.

다음은 풍속 데이터에 관한 그래프이다. 풍속 데이터와 풍향 데이터는 강원도 대관령 기상대에서 관측되는 시간별 데이터이며 기상청(www.kma.go.kr) 지상관측자료에서 수집하였다. Figure 3.3은 시간에 따른 풍속에 대한 그래프이며, 풍력발전으로 인한 발전량과 유사한 추세를 보이고 있는 것을 그림을 통해 확인 할 수 있다. Figure 3.4는 풍속에 따른 풍력발전량 그래프이다. 풍속이 빨라질수록 발전량이 증가하고 있는 양상이다.

풍력발전기는 비행기 날개와 같이 양력에 영향을 받는다. 맞바람이 강할수록 양력이 커지므로 풍향이 발전량에 영향을 끼친다고 할 수 있다. 본 연구에서 풍향 데이터는 방향을 측정할 수 없을 정도로 평은




Figure 3.3. Time plot for wind speed data.




Figure 3.4. Wind speed vs wind power generation.

Table 3.1. Direction of the wind

풍향	각도(°)	풍향	각도(°)	풍향	각도(°)
정온	0.0	남동	135.0	서	270.0
북북동	22.5	남남동	157.5	서북서	292.5
북동	45.0	남	180.0	북서	315.0
동북동	67.5	남남서	202.5	북북서	337.5
동	90.0	남서	225.0	북	360.0
동남동	112.5	서남서	247.5		

한 상태 “정온”과 16방위를 사용하였다. 16방위는 동을 90°, 남을 180°라는 식으로 각도로 나타내며 북을 기준으로 동일한 간격으로 각 방향을 각도로 나타낸 결과 Table 3.1과 같다. Figure 3.5는 풍향에 따른 풍력발전량 그래프이다. Figure 3.5을 통하여 동(90°), 서(270°)와 같은 특정 방향에서 발전이 활발함을 알 수 있다. 본 논문에서는 신경망 모형에서의 풍속을 명목변수로서 사용을 하였다.

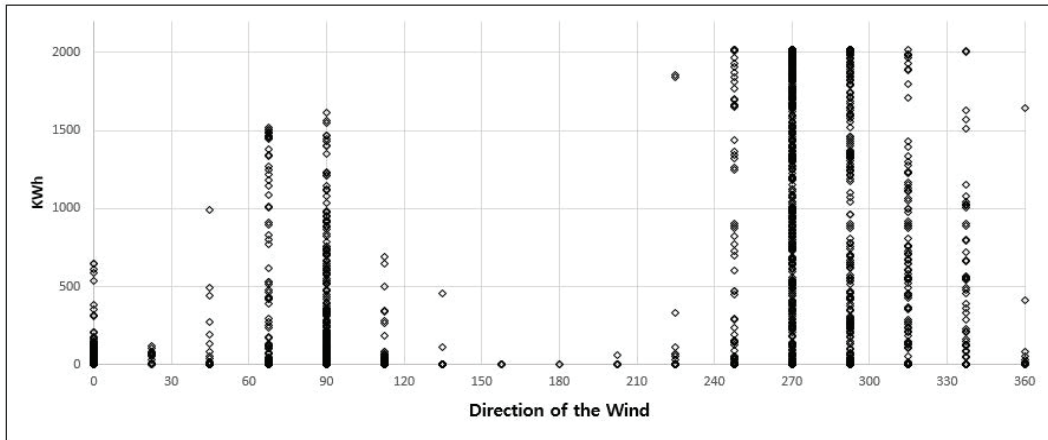


Figure 3.5. Direction of the wind vs wind power generation.

Table 3.2. Neural network results across tuning parameters

Size (Hidden layer)	Decay	RMSE	Rsquared
1	0e+00	8.1468	0.4022
1	1e-04	7.6006	0.4503
1	1e-01	6.7672	0.5421
3	0e+00	7.1001	0.5076
3	1e-04	6.5713	0.5927
3	1e-01	6.1780	0.6271
5	0e+00	6.5017	0.5785
5	1e-04	6.3910	0.5965
5	1e-01	6.1321	0.6322

3.2. 모형 적합 결과

신경망 모형의 경우, 풍향 데이터와 풍속 데이터를 이용하여 풍력발전량을 예측하기 위해 입력 노드가 2개, 은닉 노드가 5개인 NN(2, 5) 모형을 이용하였다. Table 3.2를 보면 은닉층의 노드 개수가 5이고 decay가 1e-01일 때 root mean square error(RMSE) 값이 6.1321로 가장 작은 값을 가지며 설명력이 가장 높다는 것을 확인 할 수 있다. 이 모형이 NN(2, 5)이다. RMSE는 다음 식 (3.1)과 같이 정의된다.

$$RMSE = \sqrt{MSE(\hat{\theta})} = \sqrt{E\left(\left(\theta - \hat{\theta}\right)^2\right)} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{1,i} - x_{2,i})^2}. \quad (3.1)$$

ARMA, ARMAX, ARMA-GARCH, Holt Winters 모형은 Akaike’s information criterion(AIC)를 기준으로 AIC 값이 최소인 모형을 선택하였다. 그 결과, ARMA 최적 모형은 ARMA(5, 2)이고, 포트만 트 검정(Portmanteau test) 결과 잔차의 독립성이 만족되었다. 이 모형의 모수추정치는 Table 3.3과 같다. ARMAX 모형의 최적 모형은 ARMAX(1, 1)이다. 이 모형의 모수추정치는 Table 3.4와 같다. 여기서 γ_1 은 풍향에 대한 변수의 모수이다. Holt Winters의 경우, 3-24시간 주기를 고려한 결과 3시간 주기일 때 AIC 값이 16,887.38로 가장 작았다. Table 3.5는 계절 주기가 3일 때, 모수추정치이다. 마지막으로 ARMA-GARCH 모형은 AIC가 4.7850으로 가장 작은 ARMA(1, 1)-GARCH(1, 4)를 선택하였다. 이 모형 모수는 Table 3.6과 같다.

Table 3.3. Parameters estimation of ARMA(5, 2)

Parameter	Estimate	s.e.	p-value
μ	9.5314	1.5163	< .0001
ϕ_1	1.1904	0.0234	< .0001
ϕ_2	-1.2888	0.0361	< .0001
ϕ_3	1.1561	0.0385	< .0001
ϕ_4	-0.2049	0.0361	< .0001
ϕ_5	0.0661	0.0234	< .0001
θ_1	-0.0918	0.0018	< .0001
θ_2	1.0000	0.0028	< .0001

Table 3.4. Parameters estimation of ARMAX(1, 1)

Parameter	Estimate	s.e.	p-value
μ	9.1495	1.2116	< .0001
ϕ_1	0.9484	0.0077	< .0001
θ_1	0.1679	0.0250	< .0001
γ_1	0.3375	0.0492	0.0696

Table 3.5. Parameters estimation of HW(3)

Parameter	alpha	beta	gamma
HW(3)	0.9999	0.0032	1e - 04

Table 3.6. Parameters estimation of ARMA(1, 1)-GARCH(1, 4)

Parameter	Estimate	Std. Error	t value	Pr(> t)
μ	20.012330	1.088958	18.377500	0.000000
ϕ_1	0.887706	0.003358	264.324500	0.000000
θ_1	0.197357	0.031974	6.172370	0.000000
α_0	0.290414	0.351833	0.825431	0.409127
α_1	0.462477	0.033385	13.852680	0.000000
β_1	0.418430	0.137142	3.051071	0.002280
β_2	0.000001	0.055272	0.000025	0.999980
β_3	0.029428	0.032486	0.905853	0.365014
β_4	0.088665	0.027225	3.256698	0.001127

3.3. 모형 비교 및 예측 성능 평가

모형 성능에 대한 평가 기준으로 mean absolute error(MAE)를 사용하였다. MAE는 식 (3.2)와 같이 정의된다.

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t|. \quad (3.2)$$

이 때, n 은 데이터 수이며 Y_t 는 t 시점에서의 실제 값, F_t 는 t 시점에서의 예측 값이다. MAE 값이 작을 수록 실제 값과 예측 값의 차이가 평균적으로 작다는 것을 의미한다.

본 논문에서는 슬라이딩 윈도우(sliding window) 방법을 통하여 1시점 이후 예측 부터 24시점 이후 예측을 실시하였다. 모형별 MAE는 다음 Table 3.7과 같으며 1시간에서 3시간 이후 예측에서는 ARMA-GARCH 모형의 MAE가 가장 작아 우수한 모형으로 나타났으며, 다음으로 ARMAX 모형이 MAE가 작은 것으로 나타나, 1-3시간 이후 예측에서는 ARMA-GARCH 또는 ARMAX 모형이 적합할 것으로

Table 3.7. MAE of of k -step ahead rolling forecast with re-estimation

MAE	NNet	ARMA	ARMAX	ARMA-GARCH	HW
1 ahead	196.8167	181.0132	178.4614	176.9138	186.8734
3 ahead	338.9528	353.9141	335.3630	334.1478	346.8998
6 ahead	446.2787	493.6019	463.4040	458.8865	468.8229
12 ahead	433.5535	584.1565	562.3003	540.0612	611.6635
18 ahead	441.5432	631.0166	607.8599	602.8323	784.2909
24 ahead	435.1127	628.2469	612.5008	603.8719	921.3501

나타났다. 6시간 이후 예측부터는 신경망 모형의 수치가 가장 작은것으로 나타났다.

4. 결론

매장된 지하자원의 한계, 환경 보호의 중요성이 증가로 인하여 신재생에너지에 대한 관심이 증가하고 있다. 특히 태양에너지와 풍력에너지를 이용한 산업이 성장하고 있다. 풍력발전 산업이 성장하고 의존율이 높아질수록 안정적인 공급이 중요해질 것이다. 이에 대비하여 풍력발전량 데이터, 풍속 데이터, 풍향 데이터를 활용하여 신경망 모형과 시계열 모형을 통한 풍력발전량의 예측을 실시하였다. 이 때, 풍력발전량 데이터는 변동성이 크기 때문에 Box-Cox 변환하여 분산을 비교적 안정화시킨 후 다양한 시계열 예측 모형을 시도하였다.

슬라이딩 윈도우(sliding window) 방법을 통하여 1주일간의 테스트 데이터에서의 예측 기간 별 모형을 평가한 결과, 1시간에서 3시간의 미래예측에서는 시계열 예측 모형 중 ARMA-GARCH이 타 모형에 비하여 우수한 성능을 보여주고 있다. 6시간 이후에 경우는 신경망 모형이 가장 작은 MAE로 우수한 성능을 보여주는 것을 확인할 수 있었다. 즉, 예측 기간에 따라 최적 모형을 달리 해야함을 확인할 수 있었다.

본 논문에서 사용된 풍속과 풍향 데이터는 강원도 대관령 기상대에서 관측되는 시간별 데이터였다. 하지만 풍력발전기와 같은 위치에서 수집되는 데이터를 활용하면 ARMAX 모형 등에서 더 나은 결과를 얻을 것으로 예상된다. 또한 1시간이 아닌 10분 단위의 데이터를 활용하면 변동성이 더 커지므로 GARCH 모형을 통해 풍력발전량을 연구하면 더 좋은 결과를 얻을 수 있을 것으로 예상된다. 향후적으로 Box-Cox 변환 방법을 확장하여 적용모형 기반 Box-Cox 변환 방법에 대한 추가적인 연구를 진행해야 할 것으로 사료된다.

References

- Alexiadis, M. C., Dokopoulos, P. S., Sahsamanoglou, H. S., and Manousaridis, I. M. (1998). Short-term forecasting of wind speed and related electrical power, *Solar Energy*, **63**, 61–68.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity, *Journal of econometrics*, **31**, 307–327.
- Brown, B. G., Richard W. K., and Allan H. M. (1984). Time series models to simulate and forecast wind speed and wind power, *Journal of climate and applied meteorology*, **23**, 1184–1195.
- Byun, H. I., Ryu, J. Y., and Kim, D. H. (2005). The Study of the Wind Resource and Energy Yield Assessment for the Wind Park Development, *Journal of the Korean society for New and Renewable Energy*, **1**, 19–25.
- Chitsaz, H., Amjady, N., and Zareipour, H. (2015). Wind power forecast using wavelet neural network trained by improved Clonal selection algorithm, *Energy Conversion and Management*, **89**, 588–598.
- Engle, R.F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United

- Kingdom inflation, *Econometrica: Journal of the Econometric Society*, **50**, 987–1007.
- Hill, D. C., McMillan, D., Bell, K. R., and Infield, D. (2012). Application of auto-regressive models to UK wind speed data for power system impact studies, *IEEE Transactions on Sustainable Energy*, **3**, 134–141.
- Hwang, M. Y., Kim, S. H., Yun, U. I., Kim, K. D., and Ryu, K. H. (2012). Building of prediction model of wind power generation using power ramp rate, *Journal of the Korea Society of Computer and Information*, **17**, 211–218.
- Lee, Y. S., Kim, J., Jang, M. S., and Kim, H. G. (2013). A study on comparing short-term wind power prediction models in Gunsan wind farm., *Journal of the Korean Data and Information Science Society*, **24**, 585–592.
- Park, H. W., Jin, C.H., Kim, K. D., and Ryu, K. H. (2012). Short-term wind power prediction with power ramp rate and ANFIS approach, *The Korean Institute of Information Scientists and Engineers*, **39**, 157–159.
- Quan, H., Srinivasan, D., and Khosravi, A. (2014). Short-term load and wind power forecasting using neural network-based prediction intervals, *IEEE transactions on neural networks and learning systems*, **25**, 303–315.
- Ryu, G. H., Kim, K. S., Kim, J. C., and Song, K. B. (2009). A study on estimation of wind power generation using weather data in Jeju island, *The Transactions of the Korean Institute of Electrical Engineers*, **58**, 2349–2353.
- Shin, H. G., Lee, M. H., and Lee, J. H. (2011). Development of the wind turbine power prediction system using support vector regression, *2011 The Korean Institute of Electrical Engineers*, 696–697.
- Tol, R. S. (1997). Autoregressive conditional heteroscedasticity in daily wind speed measurements, *Theoretical and applied climatology*, **56**, 113–122.
- Torres, J. L., Garcia, A., De Blas, M., and De Francisco, A. (2005). Forecast of hourly average wind speed with ARMA models in Navarre (Spain), *Solar Energy*, **79**, 65–77.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages, *Management Science*, **6**, 324–342.

시계열 모형을 이용한 단기 풍력발전 예측 연구

박수현^a · 김삼용^{a,1}

^a중앙대학교 응용통계학과

(2016년 9월 2일 접수, 2016년 10월 12일 수정, 2016년 10월 30일 채택)

요약

풍력에너지 산업이 발전하고 풍력발전에 대한 의존율이 높아짐에 따라 안정적인 공급이 중요해지고 있다. 원활한 전력수급계획을 세우기 위해서 풍력발전량을 정확히 예측하는 것이 중요하다. 본 논문에서는 강원도 평창 황계리에 설치된 대관령 2풍력(2MW 1기)의 시간별 풍력발전 데이터와 강원도 대관령 기상대에서 관측되는 시간별 풍속과 풍향 데이터를 기상청 지상관측자료에서 수집하여 연구하였다. 풍력발전량 예측을 위하여 신경망 모형과 시계열 모형인 ARMA, ARMAX, ARMA-GARCH, Holt Winters 모형을 비교하였다. 모형 간 예측력을 비교하기 위해 mean absolute error(MAE)를 사용하였다. 모형의 예측 성능 비교 결과 1시간에서 3시간의 단기 예측에 있어서 ARMA-GARCH 모형이 우수한 예측력을 보였다. 6시간 이후 예측에서는 신경망 모형이 우수한 예측을 보였다.

주요용어: 풍력발전량, 신경망 모형, ARMAX, ARMA GARCH, Holt Winters

이 논문은 2016년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(NRF-2016 R1D1A1B01014954).

¹교신저자: (06974) 서울시 동작구 흑석로 84, 중앙대학교 경영경제대학 응용통계학과.

E-mail: sahm@cau.ac.kr