



J. Korean Soc. Aeronaut. Space Sci. 49(12), 963-969(2021)

DOI: <https://doi.org/10.5139/JKSAS.2021.49.12.963>

ISSN 1225-1348(print), 2287-6871(online)

은닉 마르코프 모델을 이용하여 계절의 변동을 동반한 인공 바람자료 생성 및 검증

박석영¹, 유기완²

Generation and Verification of Synthetic Wind Data With Seasonal Fluctuation Using Hidden Markov Model

Seok-Young Park¹ and Ki-Wahn Ryu²

Department of Aerospace Engineering, Jeonbuk National University

ABSTRACT

The wind data measured from local meteorological masts is used to evaluate wind speed distribution and energy production in the specified site for wind farm. However, wind data measured from meteorological masts often contain missing information or insufficient desired height or data length, making it difficult to perform wind turbine control and performance simulation. Therefore, long-term continuous wind data is very important to assess the annual energy production and the capacity factor for wind turbines or wind farms. In addition, if seasonal influences are distinct, such as on the Korean Peninsula, wind data with seasonal characteristics should be considered. This study presents methodologies for generating synthetic wind that take into account fluctuations in both wind speed and direction using the hidden Markov model, which is a statistical method. The wind data for statistical processing are measured at Maldo island in the Kokunnsan-gundo, Jeonbuk Province using the Automatic Weather System (AWS) of the Korea Meteorological Administration. The synthetic wind generated using the hidden Markov model will be validated by comparing statistical variables, wind energy density, seasonal mean speed, and prevailing wind direction with measurement data.

초 록

풍력발전단지 위치 선정에 있어 풍속 분포 및 발전량을 평가하기 위해 해당 지역의 기상 타워에서 측정된 바람 자료를 이용한다. 그러나 기상 타워에서 측정된 바람 자료는 종종 정보가 누락되거나 원하는 높이에 맞지 않거나, 혹은 데이터 길이가 충분하지 않아 풍력터빈 제어 및 성능 시뮬레이션 수행에 어려움을 겪게 된다. 따라서 풍력터빈 혹은 발전단지에 대한 연간 발전량 및 이용률을 평가하는데 원하는 높이에서 장기간의 연속적인 바람 자료는 매우 중요하다. 또한, 한반도와 같이 계절에 따른 풍향과 풍속 변동이 뚜렷한 경우에는 계절별 특징이 고려된 풍속과 풍향을 동반한 바람 자료를 고려해야 한다. 본 연구에서는 통계적 방법인 은닉 마르코프 모델을 이용하여 풍속과 풍향의 변동을 고려한 인공 바람을 생성하기 위한 방법을 제시한다. 통계처리를 위한 바람 자료는 전라북도 고군산군도에 있는 말도의 기상청 방재기상관측(AWS) 장비에서 측정된 자료를 사용한다. 은닉 마르코프 모델에 의해 생성된 인공 바람은 통계 변수, 풍력에너지밀도, 계절별 평균 풍속, 주 풍향 등을 측정 자료와 비교를 통해 검증하기로 한다.

† Received : September 15, 2021 Revised : November 9, 2021 Accepted : November 22, 2021

¹ Graduate Student, ² Professor² Corresponding author, E-mail : kwryu@jbnu.ac.kr, ORCID 0000-0002-4575-4493

© 2021 The Korean Society for Aeronautical and Space Sciences

Key Words : Hidden Markov Model(은닉 마르코프 모델), Synthetic Wind Data(인공 바람 자료), Wind Energy Density(풍력 에너지 밀도), Autocorrelation(자기상관)

I. 서 론

풍력터빈의 성능은 성능곡선(power curve)이나 속도비에 따른 출력계수 곡선으로 확인된다. 이 곡선은 풍력터빈을 설계하고 개발하는 기관이나 풍력터빈 시스템 공급업체(supplier) 관점에서 중요한 관심사항이다. 반면에 발전사업자나 풍력 발전단지 개발자(developer)는 연간에너지 생산량(annual energy production, AEP) 혹은 이용률(capacity factor, CF)과 같은 경제적인 개념을 갖는 척도에 더 주목한다고 볼 수 있다. 특히 AEP는 풍력터빈 혹은 풍력단지의 LCOE(levelized cost of energy)를 산출하는 중요한 변수이다. 풍력터빈 단위 기기가 되었든 아니면 풍력발전단지가 되었든 특정 지역의 풍황에 따라서 같은 기기를 설치한다 해도 연간 에너지 생산량이나 이용률은 차이를 보인다. 따라서 풍력터빈을 설치하고자 하는 지역의 경제성을 미리 평가하고자 한다면 그 지역의 풍황 자료를 확보하는 것이 무엇보다도 중요하다. 이를 위해 단지개발 이전에 기상탑(met-mast)을 설치하여 최소 1년 이상의 바람자료를 계속하는 사업이 선행된다.

시간에 따라 풍속이 변하는 바람은 유체역학적인 관점에서 난류의 특성을 갖는다고 볼 수 있다. 또한 시계열 바람의 특성은 이전의 풍속이 현재의 풍속에 영향을 주며 두 값 사이에 자기상관성이 있다는 점에서 수학 또는 통계적인 모델을 통해 분석하는 방법이 있다. 여기에 기계학습이나 딥러닝을 통해 실제 바람자료를 가장 잘 표현하는 인자를 최적으로 찾아주는 방법이 적용되고 있다. 유동이론에서 난류를 표현하는 대표적인 예로 von Karman, Kaimal, Mann 등의 유동 모델이 있으며[1], 회귀분석이나 통계적 처리를 통한 시계열 바람자료 생성 방법에는 ARMA, ARIMA, SARIMA, Markov 사슬, 은닉 Markov 사슬 등이 있다[2-7]. 후자의 방법은 다양한 시계열 변동량을 표현할 수 있는데, 예를 들면 농산물의 물가나 압축화폐의 가치, 주가 변동이나 강우량 등의 표현에 응용되고 있으며, 본 연구의 관심사인 바람에 대해서도 역시 응용되고 있다. 그러나 후자의 방법들 중 ARMA, ARIMA, SARIMA는 난류의 특성이 강한 바람과 같은 자료에 대해서는 정확한 예측 수행이 불가능하고, 차수가 높은 단점이 있어 장기간의 바람자료 생성에는 Markov 사슬이나 은닉 Markov 사슬이 적합하다고 할 수 있다[4].

Markov 사슬(chain)은 시간에 따른 상태(state)의 변화를 나타내는 모델로 과거는 현재 상태의 확률 분포에 영향을 미치며 상태의 전이를 확률로 나타내는

모델이다[5]. 시시각각으로 변하는 바람은 연속적인 값을 갖기 때문에 연속 랜덤 변수이다. 이런 랜덤 변수의 순서를 랜덤 프로세스(random process)라 하며 Markov 사슬로 모델링할 수 있다. 하지만 Markov 사슬을 통한 인공 바람 자료 생성에 있어 평균이나 표준편차와 같은 통계 변수들은 일치하여도 계절별 특징이 반영되지 않는 문제가 있다[6]. 이를 해결하기 위해 Markov 사슬의 차수를 증가시키면서 바람의 변동을 약간 개선하였지만 계절별 특징이 반영되었다고는 볼 수 없다[8]. 따라서 차수 증가에 따라 발생하는 방대한 양의 데이터 처리 문제를 해결하고 계절별 특징을 반영하기 위해서는 은닉 Markov 모델(hidden Markov model, HMM)이 기능을 할 것으로 기대된다[7].

은닉 Markov 모델은 음성인식, 상태진단, 기상예측 등과 같은 다양한 분야에서 응용되고 있다[9-11]. Jafazadeh 등[12]은 은닉상태를 24시간으로 가정하여 1시간 후의 풍속 예측을 수행하였다. Basile 등[13]은 은닉 상태를 연중 바람 패턴 수로 가정하여 풍향 예측을 수행하였다.

본 연구에서는 은닉 Markov 모델을 이용하여 장기간의 풍속, 풍향과 관련된 인공 바람 자료들을 동시에 생성하고자 한다. 계절별 특징이 반영될 수 있는 은닉 상태를 가정하여 은닉 Markov 모델을 통해 생성한 인공 바람 자료는 통계 변수, 풍력에너지밀도, 계절별 평균 풍속, 주 풍향 등에 대해 예측 바람과 비교 검증하고자 한다.

II. 본 론

2.1 풍황 자원 예측

기상청에서는 전국에 총 500여 개의 방재기상관측(AWS) 장비를 운용하고 있으며, Fig. 1과 같은 AWS는 10 m 높이에서 기온, 풍향, 풍속 등 지상부근의 다양한 대기상태를 실시간으로 관측한다.

전라북도 새만금 고군산군도에 위치한 말도는 Fig. 2와 같이 군산으로부터 남서쪽으로 약 40 km 떨어진 섬이며 특히, 말도가 위치한 고군산군도 전역에 걸쳐 바람등급이 3등급 이상으로 확인되었다[14]. 말도에 설치된 AWS로 2015년도에 관측된 자료를 예측 자료로 활용하였다.

예측 풍속의 확률분포는 Weibull 분포와 상당히 유사하며 Weibull 분포를 통해 예측 풍속의 신뢰도 평가를 수행할 수 있다. Fig. 3은 예측 풍속의 확률분포와 Weibull 분포를 비교한 것이며 Weibull 분포의 식은 다음과 같다.




Fig. 1. Automatic weather system



Fig. 2. Location of Maldo nearby Saemangeum

$$f(V) = \frac{k}{C} \left(\frac{V}{C} \right)^{k-1} \exp \left(-\left(\frac{V}{C} \right)^k \right) \quad (1)$$

$$\ln(-\ln(1-F(V))) = k \ln(V) - k \ln(C) \quad (2)$$

여기서 k 는 풍속의 분포와 관계되는 형상 계수(shape parameter), C 는 평균 풍속과 관계되는 척도 계수(scale parameter)를 나타낸다. k 와 C 를 산출하는 방법으로 식 (1)의 $f(V)$ 에 대한 지수형태의 누적확률분포 함수 $F(V)$ 에 로그를 취해줌으로써 식 (2)처럼 선형형태로 변환한다. 이때, k 는 직선의 기울기에 해당되고 y 절편을 통해 C 를 산출할 수 있다. 이렇게 계산된 k 와 C 의 값은 각각 1.61과 4.99이다.

2.2 Hidden Markov model(HMM)

Markov 사슬은 순차적인 데이터에 대해 현재 상태는 과거의 상태에만 영향을 받는다는 가정으로 현재 상태를 추정하는 확률 모델이다. Markov 사슬은




Fig. 3. Weibull distribution for wind data

입력 자료를 같은 간격으로 n 등분 하였을 때 각각의 구간을 상태라고 정의한다. 이때 각 상태는 직접 관찰이 가능하다. 또한, 계측 자료의 평균이나 표준편차 같은 주요 변수들과 일치한다 하더라도 난수발생기를 통해 계절성이 반영되지 않는 무작위적인 바람 자료가 생성되는 문제가 발생한다. 하지만 HMM의 기본 프로세스는 Markov 사슬을 따르면서 각 상태가 은닉되어 있다고 가정한다[7]. 각 상태가 은닉되어 있다는 가정으로 계절별 특징을 갖는 바람 자료 생성에 적용할 수 있을 것으로 판단된다.

N 은 관측 자료의 특징을 나누는 은닉 상태 개수이며 M 은 관측 자료를 같은 간격으로 m 등분 하였을 때 생기는 관측기호의 개수를 나타낸다. 초기상태확률(initial state probability) Π 는 특정 은닉 상태가 시간 $t=1$ 일 때의 확률을 나타내며 $N \times 1$ 행렬이다. 상태전이확률(state transition probability) A 는 t 의 어떤 은닉 상태에서 $t+1$ 의 은닉 상태로의 전이 확률이며 $N \times N$ 행렬이다. 관측확률(observation probability) B 는 특정 은닉 상태에서 관측된 관측기호의 확률이며 $N \times M$ 행렬이다. 행렬 Π, A, B 를 수식으로 나타내면 다음과 같다.

$$\Pi = \begin{bmatrix} S_1 \\ S_2 \\ \vdots \\ S_N \end{bmatrix} \quad (3)$$

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1N} \\ a_{21} & a_{22} & \cdots & a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ a_{M1} & a_{M2} & \cdots & a_{MN} \end{bmatrix} \quad (4)$$

$$B = \begin{bmatrix} b_{11} & b_{12} & \cdots & b_{1M} \\ b_{21} & b_{22} & \cdots & b_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ b_{N1} & b_{N2} & \cdots & b_{NM} \end{bmatrix} \quad (5)$$

HMM을 이용하여 바람의 시계열 자료 생성을 위해서는 HMM 변수 $\lambda = [\Pi, A, B]$ 를 학습시켜야 한다.

먼저 입력 자료를 관측기호로 분류한 후 관측기호의 특징을 N가지로 구분한다. 각 관측기호에 해당하는 최적 은닉 상태 sequence를 찾기 위해 Viterbi 알고리즘을 이용하여 결정한다. HMM 변수를 최적화하기 위해 Baum - Welch 알고리즘을 적용하는데 아래의 오차범위를 만족할 때까지 반복 계산을 통하여 HMM 변수를 재 추정한다.

$$P(O|HMM(\lambda^{new})) - P(O|HMM(\lambda^{old})) < tol \quad (6)$$

은닉 상태를 풍속과 풍향의 계절적 특징을 구분할 수 있는 값으로 가정한 후 최적의 HMM 변수가 결정되면 0과 1 사이의 랜덤 변수를 이용하여 연속적인 시간에 따른 바람 자료를 생성한다.


2.3 결과 분석

풍속과 풍향의 구간은 각 연구마다 차이가 있는데 본 연구에서는 풍속을 0.5 m/s, 풍향은 16방위로 간격을 나누었다. 풍속의 경우, 계측 풍속의 최대 풍속은 20.4 m/s이므로 $M = 41$ 이며 풍향의 경우 $M = 16$ 이다. 은닉 상태 N은 풍속과 풍향의 이질성이 계절이라는 가정으로 12개월 즉, $N=12$ 로 가정하였다. HMM을 이용하여 총 1년 동안의 바람을 생성하였고 계측 풍속과 인공 풍속의 최대 속도, 최소 속도, 평균 속도, 표준 편차를 Table 1에 수치적으로 비교하였다. 두 풍속간의 통계 변수들이 서로 높은 정확도로 일치하고 있음을 알 수 있다. Fig. 4는 일부 시간 동안의 계측풍속과 인공 풍속을 도시한 것이고, Fig. 5는 두 풍속 간 확률 밀도 분포를 상호 비교한 것이다. 풍속이 갖는 랜덤 특성상 시계열 신호간의 차이는 있어도 확률분포는 상당한 정확도로 일치함을 알 수 있다. 또한, 인공 풍속의 신뢰도를 평가하기 위해 식 (1)과 (2)를 통해 Weibull 분포를 산출하면 k와 C의 값은 각각 1.56, 5.02로 2.1절에서 언급한 k, C의 값과 큰 차이가 없음을 알 수 있다.


계측 풍속과 인공 풍속의 평균 속도와 표준편차가 일치하고 Fig. 5의 확률 분포처럼 나타나도 잘 일치

Table 1. Comparison of statistical parameters between measured and synthetic wind data

	Measured [m/s]	Synthetic [m/s]	Relative error (%)
Maximum	20.4	20.5	0.49
Minimum	0	0	0
Mean	4.72	4.67	1.06
Standard deviation	3.26	3.32	1.84



(a) Measured data



(b) Synthetic data

Fig. 4. Wind speed variation according to time




Fig. 5. Probability density distribution for measured and synthetic wind speed

한다고 단정 지을 수는 없다. 시계열 자료는 이전의 풍속이 현재의 풍속에 영향을 줄 수 있기 때문에 시간에 따른 두 풍속의 상관관계를 검토할 필요가 있다. 이때 신호의 상관관계를 확인할 수 있는 방법이 자기상관(autocorrelation) 계수이며, 다음과 같은 식으로 표현할 수 있다.

$$c_k = \frac{\frac{1}{n-k} \sum_{i=1}^{n-k} (v_i - \bar{v})(v_{i+k} - \bar{v})}{\frac{1}{n} \sum_{i=1}^n (v_i - \bar{v})(v_i - \bar{v})} \quad (7)$$

여기서 $i=1,2,3,\dots,n$, $k=0,1,2,\dots,n-1$, n 은 총 데이터의 개수이며, \bar{v} 는 평균 풍속이다. 자기상관 계수 c_k 는 1에 가까울수록 상관성이 높으며, 시간이 지날수록 상관관계가 감소한다. Fig. 6은 계측 풍속과 인공 풍속의 자기상관계수를 상호 비교한 것이다. 두 풍속들은 시간이 지날수록 자기상관 계수가 감소하면서 유사한 변화 양상을 보여주고 있다.

특정 지역의 풍황자료를 가지고 풍력터빈이 생산할 수 있는 에너지양을 파악하기 위해서 풍력에너지 밀도(wind energy density)를 조사해야 한다. 풍력에너지밀도는 바람이 가지는 에너지를 단위면적으로 표현한 것이며 아래 식처럼 나타낼 수 있다.

$$\frac{P(v)}{A} = \frac{1}{2} \rho \int_0^{\infty} v^3 f(v) dv \quad [\text{W/m}^2] \quad (8)$$

여기서 P 는 출력, A 는 풍력터빈 블레이드의 회전면적, ρ 는 공기밀도, v 는 풍속이며, $f(v)$ 는 Fig. 5의 확률 분포이다. 말도에서 계측한 풍력에너지밀도는 171.8 W/m^2 로 NREL[15]에서 제시된 10 m 높이 기준 바람에너지 3등급($150\sim 200 \text{ W/m}^2$)에 해당한다. 인공 풍속의 경우 풍력에너지밀도는 168.3 W/m^2 로 계측 풍속과 동일한 바람에너지 3등급에 해당한다. 일반적으로 바람에너지 4등급 이상이 풍력 발전에 적합하다고 하였으나 풍력터빈 대형화에 따라 유럽에서는 바람에너지 3등급도 풍력 발전이 권장되는 수준으로 평가한다. Fig. 7은 두 풍속의 풍력에너지밀도를 비교한 것이며 상대 오차 4.2%로 연간 에너지 생산 관점에서 인공 풍속의 경우 계측 풍속과 잘 일치하는 결과를 보여준다.




Fig. 6. Autocorrelation for measured and synthetic wind speed




Fig. 7. Comparison of wind energy density between measured and synthetic wind speed

HMM을 통해 생성한 인공 바람이 무작위적인 바람을 생성한 것이 아닌 계절적 특성이 반영되었다는 것을 확인하기 위해 월별 평균 풍속 및 방위 별 확률 밀도를 계측 바람과 상호 비교함으로써 검증을 수행하였다. Fig. 8은 계측 풍속과 인공 풍속의 월별 평균 풍속을 상호 비교한 것이다. 말도의 AWS에서 관측된 계측 풍속은 1월에서 6월로 갈수록 평균 풍속이 낮아지다가 12월로 갈수록 증가하는 경향을 보인다. Fig. 8은 계측 풍속과 인공 풍속의 월별 평균 풍속을 도시한 것이다. 인공 풍속의 경우 월별 평균 풍속이 계측 풍속과 유사한 경향을 보이고 있지만 6월의 평균 풍속은 계측 풍속과 다르게 평균 풍속이 크게 증가한 모습을 보이고 있다. 이와 같은 현상을 해결하기 위해 같은 해 말도의 온도와 밀도 특성 값을 적용하여 Fig. 9와 같이 6월의 평균 풍속 오차는 개선되었지만, 1~3월에 두 풍속 간 차이가 여전히 발생함을 알 수 있다. 이 문제의 해결을 위해 태양의 고도각을 특성값에 추가하여 적용한 결과 Fig. 10처럼 전반적으로 인공 풍속의 월별 평균 풍속이 계측




Fig. 8. Comparison of monthly wind speed between measured and synthetic wind speed




Fig. 9. Monthly wind speed with considering temperature and density characteristics

풍속과 상당히 유사한 모습을 보인다. 따라서 바람뿐만 아니라 온도, 밀도, 태양의 고도 등 여러 특성 값을 동시에 적용함으로써 계절별 풍속의 변동을 크게 개선하여 예측할 수 있었다.

Figure 10의 두 풍속 분포의 계절별 평균 풍속을 수치적으로 비교한 것을 Table 2에 나타내었다. 봄(3~5월), 여름(6~8월), 가을(9~11월), 겨울(12~이듬해 2월)로 계절별로 구간을 나누어 각각 비교하였다. 계측 풍속은 겨울에 평균 풍속이 가장 높고 여름에 가장 낮게 관측되었다. 또한 인공 풍속도 계측 풍속과 동일하게 여름에는 평균 풍속이 가장 낮고 겨울에 가장 크게 나타난 것을 확인할 수 있었다. Fig. 11은 계측 풍향과 인공 풍향의 각 16방위에서의 확률 밀도를 비교한 것이다. 계측 풍향의 주 풍향은 NNW와 SSE이며, 인공 풍향도 계측 풍향과 동일하게 주 풍향이 NNW와 SSE로 확인된다. 두 풍향 간 NNW와 SSE의 상대 오차는 각각 0.7%, 2.4%로 주풍향의 발생 빈도가 상당히 잘 일치함을 알 수 있다. 또한 두 풍향의 각 방위별 확률밀도들이 유사한 확률을 보였다. 전반적으로 HMM을 이용하여 생성한 인공 풍속의 경우




Fig. 10. Monthly wind speed with considering temperature, density, and solar altitude

Table 2. Comparison of mean wind speed between measured and synthetic wind data

	Measured [m/s]	Synthetic [m/s]	Relative error [%]
Spring	4.37	4.25	2.75
Summer	3.83	4.18	9.13
Autumn	4.67	5.05	8.14
Winter	6.03	5.71	5.31

전체 오차 약 7.1%, 풍향의 경우 전체 오차 약 10.1% 범위 내에서 계절별 특징을 잘 추종하는 것으로 판단된다.

지금까지 말도의 풍향 관측 통계자료와 HMM을 이용하여 인공적인 바람자료를 생성하는 결과를 보여주었다. 여기서 인공적인 바람자료는 시간에 따른 풍향과 풍속 변화를 모두 포함하는 것으로 풍력터빈 성능을 모사하기 위한 입력자료로 매우 유용할 것으로 사료된다. 특히 한반도의 경우는 풍속과 풍향이 계절적인 특성이 강하게 나타나는 지역이기 때문에 Markov 방법을 통해 이러한 특성이 월별로 반영되도록 처리하였다. 결과적으로 HMM을 이용하여 생성한 인공 바람 자료는 한반도의 전형적인 풍향 패턴이 잘 반영되는 것으로 나타났다. 또한 Weibull 분포, 자기상관 계수 등을 계측 바람과 비교하였을 때 확률 통계적 관점으로 유의미한 오차를 발생시키지 않는 것으로 나타났다. 따라서 풍력터빈을 설치하고자 하는 지역의 경제성을 평가하는 데 있어 HMM을 이용하여 생성한 계절의 영향이 반영된 장기간의 바람 자료는 이용률 및 발전량 평가를 통한 경제성 판단에 매우 유용한 자료가 될 것으로 기대된다.

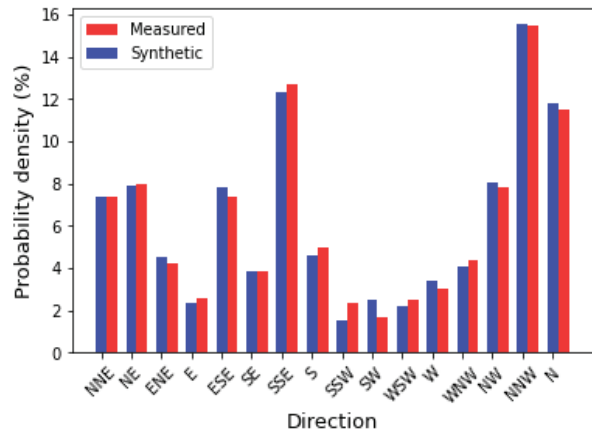


Fig. 11. Directional probability density for measured and synthetic wind data

III. 결 론

본 연구에서는 새만금 고군산군도에 위치한 말도에 설치된 10 m 높이의 AWS에서 관측된 풍속, 풍향 등의 기상자료를 바탕으로 은닉 Markov 모델을 통해 인공 바람 자료를 생성하였다. 이 인공 바람 자료는 평균속도, 표준편차, 풍력에너지밀도, 주 풍향 등 주요 통계 변수들이 계측 바람과 상당히 잘 일치하였다. 또한, 단순 바람만 적용하였을 경우 계절의 영향이 적절히 반영되지 못하는 데 반해 대기의 온도, 밀도와 태양의 고도 등 여러 특성 값을 동시에 고려해 줌으로써 한반도의 계절에 따른 풍속 변동 특성이 잘 반영되도록 할 수 있었다. 따라서 은닉 Markov 모델을 이용하여 어느 지역의 풍황에 대한 통계적 특성과 계절적 특징이 잘 반영된 인공 바람 자료를 풍력터빈의 입력 풍속으로 제공할 수 있음이 입증되었으며, 이러한 바람자료는 풍력터빈의 제어 성능 및 발전 단지의 연간 발전량을 예측하는 데 매우 유용하게 활용될 수 있을 것으로 기대된다.

후 기

본 연구는 한국전력공사의 2021년 착수 기초연구 개발 과제 연구비에 의해 진행되었음(과제번호: R21 XO01-6).

References

- 1) IEC61400-1 International Standard, 3rd edition, 2005.
- 2) Torres, J. L., Garcia, A., Blas, D. and Francisco, D., "Forecast of hourly average wind speed with ARMA models in Navarre," *Solar Energy*, Vol. 79, No. 1, 2005, pp. 65~77.
- 3) Garcia, J. L. T., Calderon, E. C., Avalos, G. G., Heras, E. R. and Tshikala, A. M., "Forecast of daily output energy of wind turbine using sARIMA and nonlinear autoregressive models," *Advances in Mechanical Engineering*, Vol. 11, No. 2, 2019, pp. 1~15.
- 4) Cadenas, E. and Rivera, W., "Wind speed forecasting in the South Coast of Oaxaca," *Renewable Energy*, Vol. 32, No. 12, 2007, pp. 2116~2128.
- 5) Balzter, H., "Markov chain models for

vegetation dynamics," *Ecological Modelling*, Vol. 126, 2000, pp. 139~154.

6) Ryu, K. W., "Use of Markov Chains for synthetic wind data generation and its statistical verification," *Journal of Wind Energy*, Vol. 12, No. 3, 2021, pp. 13~18.

7) Rabiner, L. R., "A tutorial on hidden markov models and selected applications in speech recognition," *Proceedings of the IEEE*, Vol. 77, No. 2, 1989, pp. 257~286.

8) Shamshad, A., Bawadi, M. A., Hussin, W. M. A., Majid, T. A. and Sanusi, S. A. M., "First and Second order Markov chain models for synthetic generataion of wind speed time series," *Energy*, Vol. 30, 2005, pp. 693~708.

9) Varga, A. P. and Moore, R. L., "Hidden Markov model decomposition of speech and noise," *International Conference on Acoustics, Speech, and Signal Processing*, Vol. 2, 1990, pp. 845~848.

10) Jang, M., Lee, J. M., Hwang, Y., Cho, Y. J. and Song, J. B., "Condition monitoring of rotating machine with a change in speed using Hidden Markov Model," *Transactions of the Korean Society for Noise and Vibration Engineering*, Vol. 22, No. 5, 2012, pp. 413~421.

11) Khatani, D. and Ghose, U., "Weather Forecasting Using Hidden Markov Model," *2017 International Conference on Computing and Communication Technologies for Smart Nation (IC3TSN)*, 2017, pp. 220~225.

12) Jafarzadeh, S., Fadali, S., Evrenosoglu, C. Y. and Livani, H., "Hour-ahead wind power prediction for power systems using Hidden Markov Models and Viterbi Algorithm," *IEEE PES General Meeting*, 2010, pp. 1~6.

13) Basile, S., Burlon, R. and Gurrera, D., "Analysis and modeling of wind directions time series," *2013 International Conference on Renewable Energy Research and Applications (ICRERA)*, 2013, pp. 1190~1193.

14) Kim, C. K., Jang, S. J. and Kim, T. Y., "Site selection for offshore wind farms in the southwest coast of South Korea," *Renewable Energy*, Vol. 120, 2018, pp. 151~162.

15) NREL Transforming ENERGY, Geospatial Data Science Wind Data, available online: <https://www.nrel.gov>.