



# 기계학습 기반 스택킹 앙상블 모델의 풍력 발전량 예측 성능 평가

김희찬<sup>1)</sup> · 김범석<sup>2)\*</sup>

## Evaluating the Performance of Machine Learning-Based Stacking Ensemble Models for Wind Power Prediction

Huichan Kim<sup>1)</sup> · Bumsuk Kim<sup>2)\*</sup>

Received 21 July 2025 Revised 18 August 2025 Accepted 19 August 2025 Published online 11 September 2025

**ABSTRACT** The expansion of wind power generation facilities, a form of variable renewable energy (VRE), has increased the need for accurate wind power generation forecasting to mitigate instability in power grids. With advances in computational technology, machine-learning-based approaches for wind power prediction have gained significant attention, with ensemble models demonstrating notably high prediction accuracy. Among these, stacking models are particularly effective, as they enhance prediction performance by integrating the strengths of multiple individual models. However, the downstream effects of wind turbines can create differences in output between upstream and downstream units, highlighting the importance of evaluating prediction performance at both the individual turbine and wind farm levels to improve overall power system stability. Accordingly, this study assessed the power generation prediction performance of 15 individual turbines and the aggregate wind farm using four base stacking models namely, support vector machine, random forest, XGBoost, and artificial neural network and three combined stacking models.

**Key words** Wind power prediction(풍력 발전량 예측), Machine learning(기계학습), Ensemble(앙상블), Stacking(스택킹), LDAPS(국지예보 모델)

### 1. 서론

전 세계적으로 풍력발전 설비는 1,136 GW의 누적 설비용량에 도달했다.<sup>[1,2]</sup> 하지만, 풍력발전과 같은 변동성 재생에너지(Variable Renewable Energy, VRE) 자원은 간헐적 특성으로 인해 계통 운영의 측면에서 부담을 줄 수 있

다.<sup>[3~5]</sup> 이에 따라, 국제에너지기구(International Energy Agency, IEA)는 VRE 발전 비중별 계통 연계 방안을 6단계로 제시했는데, 2단계(3~15%)부터 개별 재생에너지원의 발전량 예측 시스템 구축을 권장하고 있다.<sup>[6,7]</sup> 또한, 한국전력거래소(Korea Power Exchange, KPX)는 20 MW를 초과하는 재생에너지 발전설비를 대상으로, 계통 불안정성 완화 및 운영 효율성 확보를 위해 발전량 예측제도를 시행하고 있다.<sup>[8]</sup> 특히, 풍력발전 간헐성 대응 방안으로 이러한 발전량 예측 기술이 중요하게 인식되고 있어, 정확도 향상을 위한 연구 필요성이 증가하고 있다.

최근에는 더 정확하고 효율적인 결과를 얻기 위해 기계

1) Manager, VPPlab Corp.

2) Professor, Faculty of Wind Energy Engineering, Graduate School, Jeju National University

\*Corresponding author: [bkim@jejunu.ac.kr](mailto:bkim@jejunu.ac.kr)

Tel: +82-64-754-4402

Fax: +82-64-702-2479

학습을 이용한 풍력 발전량 예측 사례가 늘어나고 있다.<sup>[9]</sup> 그중 앙상블(ensemble) 모델을 이용한 사례가 높은 예측 정확도를 보이는 것으로 보고되고 있다.<sup>[10]</sup> 앙상블 모델은 연산 과정과 학습기(learner) 종류에 따라 Bagging, Boosting, Stacking으로 구분된다. Bagging은 전체 데이터에서 중복을 허용한 샘플 데이터를 무작위로 선별해 학습시킨 후, 각 모델의 예측 결과를 평균하여 최종 예측값으로 산출하는 방식이다.<sup>[11]</sup> Boosting은 반복적으로 여러 학습기를 학습시켜 잔차(residual)를 감소시키는 방법으로 연산한다.<sup>[12]</sup> Stacking은 서로 다른 모델의 장점을 반영한 예측이 가능해<sup>[13]</sup> 예측 변동성을 줄일 수 있는 장점이 있다.<sup>[14]</sup>

Wangjie Liu 등과 Sinvaldo R. Moreno 등<sup>[15]</sup>은 Stacking 모델이 Bagging과 Boosting 연산만 하는 모델보다 예측 성능이 우수하다는 결과를 보였다. 그러나 이들 연구는 일부 풍력터빈에 국한된 결과이며, 단지 규모의 발전량 예측 성능에 관한 비교 결과를 제시하지 못했다는 점에서 한계가 있다. 특히, 풍력단지 내 터빈 간 후류 영향은 전-후방 터빈의 출력 차이(10~20%)를 초래하므로<sup>[16,17]</sup> 터빈의 설치 위치에 따른 발전량 예측 정확도 차이가 발생한다. 따라서, 풍력 발전량의 예측 정확도 평가는 개별 풍력터빈 단위에서 발전단지 규모로 확장될 필요가 있다.

본 연구는 SVM(support vector machine), ANN(Artificial Neural Network), RF(Random Forest), XGB(eXtreme Gradient Boosting)의 기계학습 기반의 독립 모델과 이들 모델을 조합한 Stacking 모델의 풍력 발전량 예측 성능을 평가했다. 연구 대상 사이트는 제주 동북·북촌 풍력발전 단지(Dongbok·Bukchon Wind Farm, DBWF)이다.

## 2. 풍력발전 단지 및 데이터 취득

### 2.1 연구 대상 풍력발전 단지

Fig. 1에 나타난 바와 같이, DBWF는 한라산을 중심으로 북동쪽에 위치하며 가까운 해안선으로부터 약 1.5~3 km 떨어져 있는 육상 풍력발전 단지이다. 발전단지 주변에는 채석장 2개소, 환경자원순환센터와 동부 쓰레기 매립장이 위치 해있고, 약 3~5 m 높이의 나무로 이루어진 숲속 지대에 조성되었다. 총 설비용량은 30 MW이며 Table 1의 제원

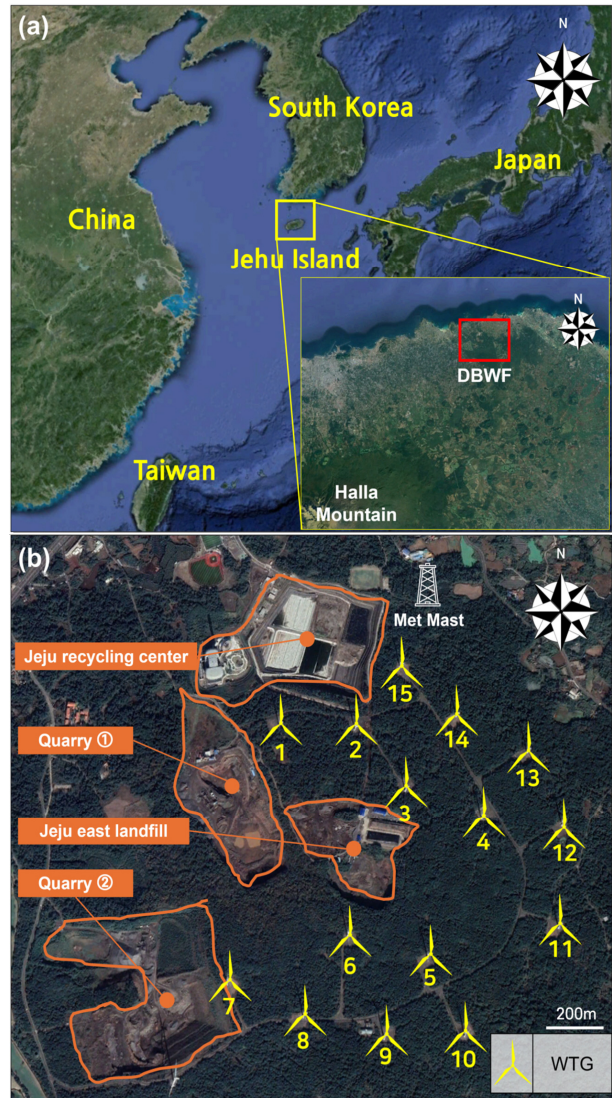


Fig. 1. Information on study site: (A) is location of DBWF in Jeju Island, South Korea and (b) is layout of Wind Turbine in the DBWF and The surrounding terrain information

Table 1. Information of wind turbine in DBWF

Description	Value
Type	3 blades, upwind
Cut-in wind speed [m/s]	3.5
Rated, wind speed [m/s]	12.5
Cut-out wind speed [m/s]	25
Pitch control	collective pitch control
Rated power [MW]	2
Hub height [m]	80
Rotor diameter [m]	87
Blade length [m]	42.2

을 갖는 15기의 풍력터빈이 설치되어 있다. 주 풍향은 북서풍이며 평균 풍속은 약 5.30~6.02 m/s이다.<sup>[18,19]</sup>

### 2.2 실증용 데이터 확보

본 연구는 감시 제어 및 데이터 취득 장치(Supervisory Control and Data Acquisition, SCADA)로부터 얻어진 2년간(2019-2020)의 터빈별 출력 데이터와 국지예보모델(Local Data Assimilation and Prediction System, LDAPS) 데이터를 사용했다. LDAPS 데이터는 예측 정확도를 높이기 위해<sup>[20]</sup> 로터 회전 면적을 커버하는 93 m, 60 m 층(layer)에서의 풍속과 풍향 변수를 사용했다. Fig. 2는 LDAPS 데이터를 이용한 풍향 정보 분석 결과이다.

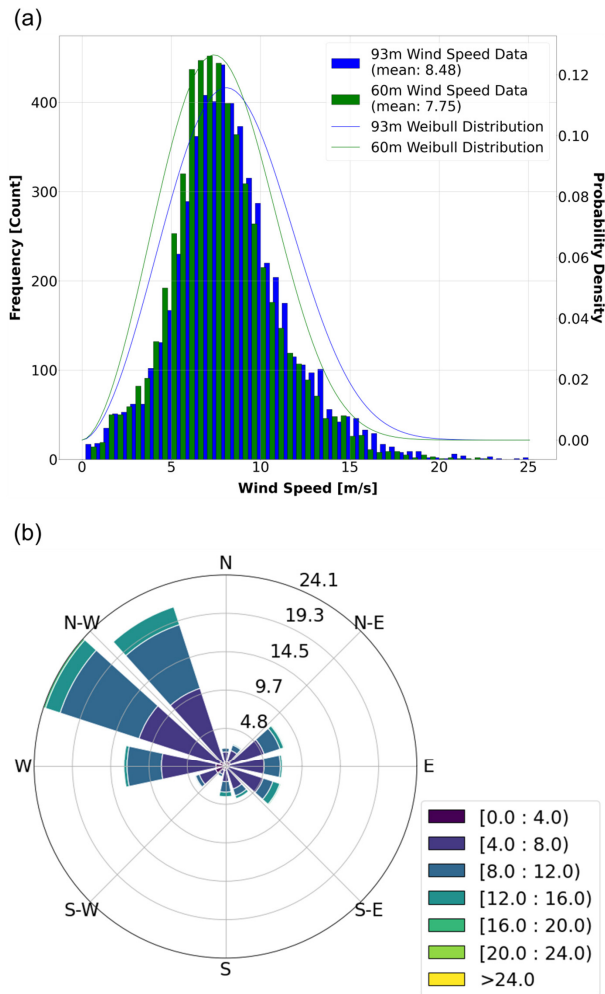


Fig. 2. LDAPS wind resource information. (a) shows the wind speed distribution for a 93 m layer (green) and 60 m layer (blue). (b) shows a 60 m layer LDAPS wind direction as the wind roses

Fig. 2(a)는 93 m와 60 m 층의 LDAPS 풍속 빈도와 와이بل(weibull) 분포이며, 60 m 층의 평균 풍속이 7.75 m/s로 DBWF와 유사하게 나타났다.

Fig. 2(b)는 60 m 층의 LDAPS 데이터를 이용해 나타낸 바람 장미(wind rose) 분포로 뚜렷한 북서풍 계열의 주 풍향이 관찰된다.

### 2.3 데이터 전처리

SCADA 데이터에는 터빈의 운영 및 유지보수로 인한 가동정지, 전력 생산의 불안정, 데이터 수집 센서의 성능저하 및 오작동 등으로 이상치(outlier)가 발생할 수 있다.<sup>[21]</sup> 이는 예측 모델 성능에 영향을 미칠 수 있으며, 본 연구에

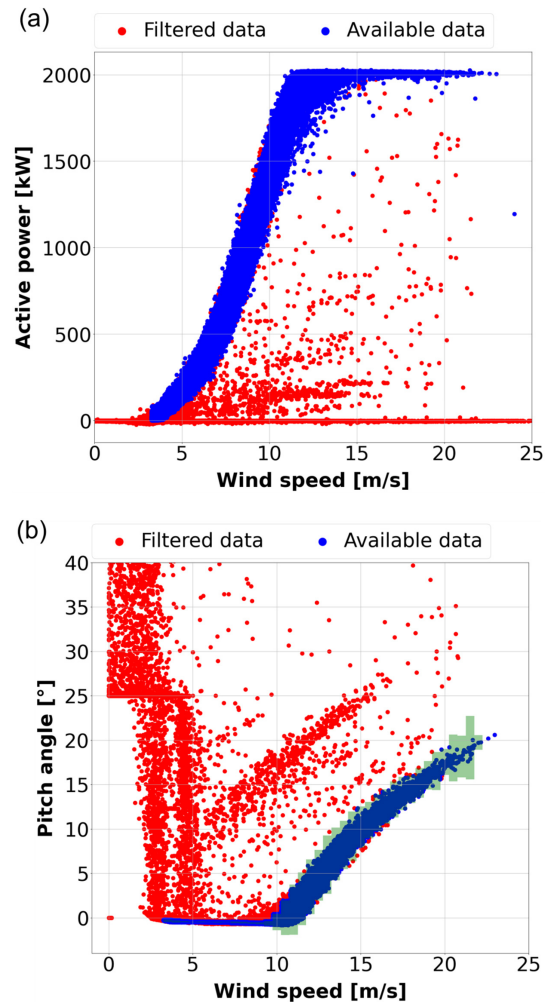


Fig. 3. Available and filtered data. The red color data is applied filtering method 1-3. The blue color data is used. The green range represents a 4.5 MAD range of pitch angle for each 0.5 m/s wind speed bin

서는 이상치를 제거하기 위해 총 3가지의 데이터 필터링 (filtering)을 적용했다. 첫 번째는 전체 풍속 구간에서 출력이 0 kW 이하인 데이터를 제거했다. 두 번째로 0.5 m/s 풍속 구간(bin)의 시동풍속보다 낮은 풍속(3.25 m/s 이하) 데이터를 제거했다. 세 번째는 Clara M. St. Martin 등<sup>[22]</sup>의 연구에 사용된 필터링 방법으로 0.5 m/s 풍속 간격의 피치각(pitch angle) 데이터에서 중앙값(median) 기준 4.5 중앙값 절대 편차(median absolute deviation, MAD) 범위 밖 데이터를 제거했다.

Fig. 3은 앞서 언급한 기준을 통해 15호기에서 취득한 가용 데이터를 필터링한 출력분포 결과이다. 필터링 적용 이후의 터빈별 평균 데이터 가용률은 56.9%(#59,870)로 나타났다. 최종적으로 사용된 유효데이터는 모든 터빈이 정상 가동 중인 시간대의 데이터를 취합해 1시간 단위를 기준으로 6,775개이다. 이중 기계학습 모델의 학습(train) 데이터로 82.04%(2019.1~2020.6, #5,558)를 사용했고, 시험(test) 데이터로는 17.96%(2020.7~2020.10, #1,217)의 유효데이터를 사용했다.

### 3. 풍력 발전량 예측 모델 및 평가 방법

#### 3.1 기계학습 알고리즘

본 연구에 사용된 기계학습 알고리즘은 ANN, SVM, RF, XGB 4가지와 이를 조합한 3가지의 Stacking 모델이다. ANN은 데이터에서 복잡한 패턴과 연관성을 학습하고 예측할 수 있어,<sup>[23]</sup> 물리적 방정식으로 설명하기 어려운 문제에 유용하다.<sup>[24]</sup> SVM은 데이터 포인트를 분리하는 최적의 분리 초평면(separating hyperplane)을 찾는 것을 목표로 하며,<sup>[25]</sup> 선형, 비선형 데이터를 예측한다. RF는 다수의 의사결정 트리(decision tree)로 중복이 가능한 데이터를 추출하고 연산하는데<sup>[26]</sup> 입력변수 중 가장 성능이 우수한 트리를 분할하고 평균하여 일반화 성능을 확보한다. XGB는 여러 개의 약한 학습기(weak learners)를 순차적으로 학습시키면서 이전 학습기의 오차를 개선해 나가는 방식으로 높은 예측 정확도를 확보한다.<sup>[27]</sup>

Stacking 모델은 여러 개의 단일 모델을 조합하여 예측 성능의 향상을 기대할 수 있는 것으로 알려져 있다. Fig. 4

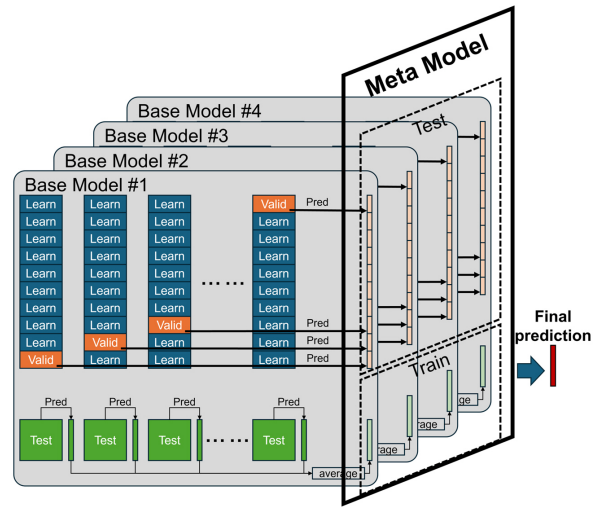


Fig. 4. The structure of stacking model. In stacking model, The base model#1~#4 is ANN, SVM, RF, XGB and meta model is SVM

는 본 연구에 사용된 Stacking 모델의 구조도이며 기본모델(base model)과 메타모델(meta model)로 구성된다. 기본모델이 학습데이터 내에 분할된 검증데이터를 예측하고 이를 취합해 메타모델의 학습데이터로 사용한다. 기본모델을 이용해 예측한 시험데이터는 평균하여 메타모델의 시험데이터로 사용한다. Stacking 모델은 SVM, ANN, RF, XGB 중 가장 성능이 우수한 2, 3종을 조합한 것을 S1, S2로 정의하고 4종 모두를 조합한 것을 S3로 정의했다. 또한, 기본모델이 예측한 데이터를 메타모델이 이용하면서 발생할 수 있는 문제를 해결하기 위해 Stacking 모델의 메타 모델로 SVM을 적용했다.

#### 3.2 하이퍼 변수 최적화

기계학습 모델의 하이퍼파라미터 최적화(Hyper-Parameter Optimization, HPO)는 예측 모델 성능에 직접적인 영향을 미친다.<sup>[28]</sup> HPO는 기계학습 모델의 학습 과정에서 자동으로 조정되지 않기 때문에 특정 방법으로 값을 지정해야 한다. HPO를 적용하는 방법은 Random search, Grid Search, Bayesian Optimization 등이 있다. SVM, ANN, RF, XGB 모델과 Stacking 모델의 HPO를 각각 적용했으며, 특히 Stacking 모델은 기본모델과 메타모델의 HPO를 모두 적용하기 때문에 연산 과정이 복잡하고, 기본모델보다 많은 연산시간이 필요하다. 따라서 본 연구에서는 연산시간이

Table 2. Grid search list for hyper-parameter optimization. Each model parameter applies the optimal value from the grid search list. SVM was used as the base model and meta model of the stacking model, and a new HPO was applied when it was applied as the meta model

Model	Parameters	default	List of grid search
SVM	gamma	scale	[0.001, 0.01, 0.1, 1, 10, 100, 1000]
	C	1.0	[0.001, 0.01, 0.1, 1, 10, 100, 1000]
	kernel	rbf	['linear', 'rbf', 'sigmoid']
ANN	hidden_layer_sizes	(100,)	[(50), (50, 25), (50, 25, 5), (100), (100, 50), (100, 50, 25), (150), (150, 75), (150, 75, 35), (200), (200, 100), (200, 100, 50)]
	activation	relu	['relu', 'tanh']
RF	n_estimators	100	[100, 300, 500, 700]
	max_depth	None	[5, 10, 15, 20]
	max_features	auto	[1, 5, 9, 13]
	min_samples_leaf	1	[1, 5, 9, 13]
	min_samples_split	2	[1, 5, 9, 13]
XGB	n_estimators	100	[100, 300, 500, 700]
	max_depth	None	[5, 10, 15, 20]
	colsample_bytree	None	[0.25, 0.5, 0.75, 1]
	subsample	None	[0.25, 0.5, 0.75, 1]
	learning_rate	None	[0.01, 0.05, 0.1, 1]

가장 빠른 Grid Search를 이용해 HPO를 적용했다. Table 2는 Grid Search를 적용한 모델별 HPO 매개변수와 리스트 나타냈다. 이를 이용하여 가장 최적의 값을 개별 풍력터빈과 발전단지의 발전량 예측 모델에 적용했다.

### 3.3 성능 평가 지표

기계학습 기반의 풍력 발전량 예측 모델 성능을 평가하기 위해 사용된 지표는 평균절대오차(Mean Absolute Error, MAE), 설비용량 대비 예측오차율(scaled MAE), 결정계수(R-square, R2), 평균제곱근오차(Root Mean Square Error, RMSE)로 총 4가지다. 각 성능지표 수식은 식 (1)~식 (4)에 나타냈으며  $y_i$ 는 실측값,  $\hat{y}_i$ 은 예측값,  $\bar{y}_i$ 는 예측값의 평균값을 의미한다. scaled MAE 수식에서 Wind capacity는

설비용량을 의미하며 풍력발전 단지는 30 MW, 풍력터빈은 2 MW이다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{1}$$

$$scaled\ MAE = \frac{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|}{Wind\ capacity} \times 100 \tag{2}$$

$$R^2 = 1 - \frac{SSR}{SST} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \tag{3}$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{4}$$

## 4. 결과 및 고찰

### 4.1 개별 풍력터빈 발전량 예측 결과

Fig. 5에 DBWF에 설치된 15개 터빈과 LDAPS 층간 데이터의 풍속 차이를 나타냈다. 전체 터빈의 중앙값 평균을 기준으로 93 m와 60 m LDAPS 데이터 오차는 각각 1.7 m/s, 1.3 m/s로 나타났다. 터빈 호기별 LDAPS 데이터의




Fig. 5. The box-plot of wind speeds differing from LDAPS and the observed wind speed data from SCADA for each turbine

오차 변동성이 관찰되는데 특히 15호기 터빈의 오차가 가장 낮게 나타났다. 이는 Fig. 1에 나타난 것처럼 15호기 터빈이 주 풍향을 기준으로 가장 적은 후류 영향에 노출되어 있기 때문으로 판단된다.

Fig. 6은 개별 풍력터빈을 대상으로 한 예측 모델별 scaled MAE 결과를 나타내며, 평균값이 낮은 순서대로 터빈 호기를 나열했다. 후류 영향을 많이 받을 것으로 예상되는 10~12호기 등이 상대적으로 낮은 값을 보이는데, 이는 전망에 설치된 터빈들이 자연환경순환센터, 채석장, 쓰레기매립장 등 주변 장애물의 영향을 크게 받기 때문이다. 또한, 1호기부터 15호기까지 모든 터빈에서 Stacking 모델(S1~S3)의 scaled MAE가 더 낮게 분포하는 특징을 보여 기본모델에 비해 후류 영향을 받는 풍력터빈의 발전량 예측 성능이 더 우수한 것으로 나타났다.




Fig. 6. A comparison of the prediction error rates for each turbine is presented. The turbine numbers on the y-axis are listed in ascending order, from the turbine with the lowest average value across the prediction models to the highest

## 4.2 풍력발전 단지 발전량 예측 결과

Fig. 7은 모델별 풍력발전 단지 발전량 예측 결과를 나타낸다. 여기서 S1은 SVM·XGB, S2는 SVM·XGB·RF를

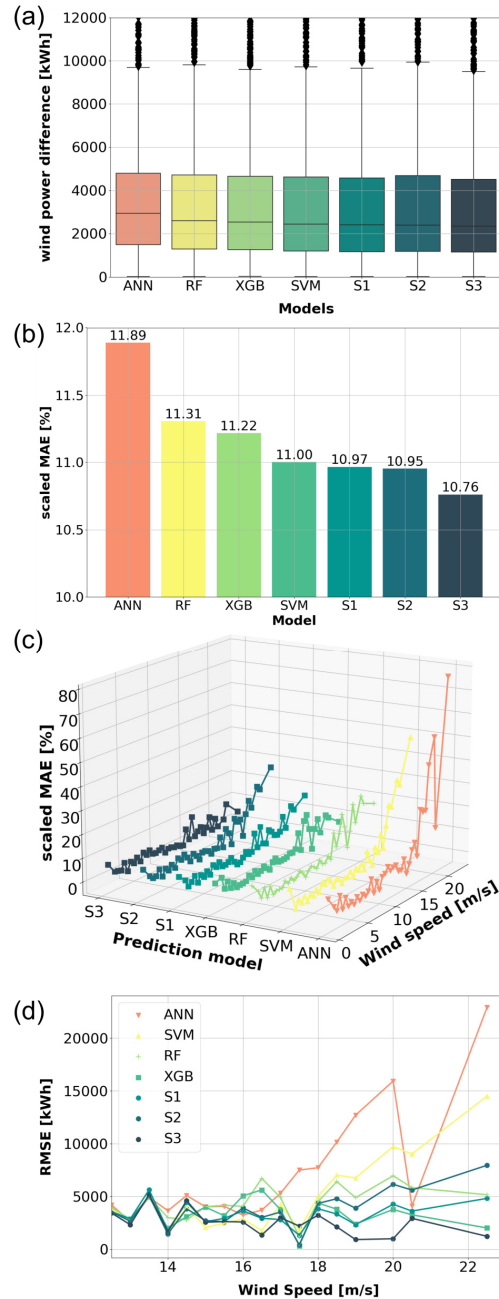


Fig. 7. Scaled MAE for each wind power prediction model. (a) is a boxplot of the difference between the measured values and the predictions for each model, (b) is the overall scaled MAE for each model, and (c) is the scaled MAE for each model for each 60 m LDAPS wind speed bin, (d) is the RMSE performance metric result for each model for each 0.5 m/s wind speed bin at wind speeds above the rated wind speed (12.5 m/s)

결합한 Stacking 모델이다. Fig. 7(a)는 SCADA에 기록된 실제 발전량과 모델별 예측 발전량의 차이를 보여준다. Stacking 모델인 S1, S3의 발전량 차이가 가장 낮게 나타났고, 이 중에 S3의 예측 성능이 가장 우수한 것으로 확인된다. Fig. 7(b)는 모델별 scaled MAE를 보여준다. S3 모델이 가장 우수한 성능을 보이며 ANN 모델보다 예측 성능이 1.13% 더 높게 나타났다. Stacking 모델인 S1~S3의 scaled MAE를 비교할 때 S1과 S2의 성능이 비슷한 결과를 보이는데, 이는 RF와 XGB 모델 둘 다 의사결정트리 기반의 모델로써 예측 성능이 서로 유사하기 때문으로 판단된다. 반면 S3 모델은 다수의 기본모델에 ANN 모델이 추가되면서 예측 성능이 향상된 것으로 분석된다. Fig. 7(c)에 0.5 m/s의 풍속 구간별로 예측 모델별 scaled MAE를 나타냈다. 15 m/s 이하에서 모든 모델의 scaled MAE가 10% 이하로 나타났으나, ANN과 SVM 모델은 15 m/s 이상에서 높은 변동성을 보이면서 값이 증가했다. 반면, Stacking 모델은 고풍속 영역에서도 낮은 변동성과 scaled MAE를 보여 기본모델에 비해 안정적인 예측 성능을 보였다. Fig. 7(d)는 정격풍속(12.5 m/s) 이상의 풍속 조건에서 모델별 RMSE 결과를 보여준다. ANN, SVM 모델은 고풍속 영역에서 상대적으로 높은 RMSE 값과 큰 변동성을 나타냈던 반면에, Stacking 모델들은 상대적으로 낮은 RMSE를 보였고 풍속 변화에 대해 더 안정적인 예측 성능을 보였다.

Fig. 8에 LDAPS 데이터 예보 시간대마다의 모델별 scaled MAE를 히트맵으로 나타냈다. 특정 시간대에서 모든 예측

모델의 scaled MAE가 증가했는데 특히, 7시, 12~16시, 20시에서 높게 나타났다. 이는 하루 중 일출, 최대 일사량, 일몰에 해당하는 시간대로 대기환경과 기상 조건의 변화가 커서 LDAPS 데이터의 예측 정확도가 낮아졌기 때문이라 판단된다. 모델별 예측 성능 비교 결과, 앞선 결과들과 마찬가지로 Stacking 모델들의 예측 성능이 상대적으로 우수한 것으로 나타났다.

Table 3은 각 모델의 성능 평가 결과이다. 4종의 성능지표 모두에서 Stacking 모델의 예측 성능이 우수하게 나타났는데, 그중에 S3 모델이 가장 우수한 예측 성능을 보였다. S3 모델은 타 예측 모델 대비 최대 1.1% 더 낮은 scaled MAE를 보이며, RMSE를 기준으로 최대 219.0 kWh의 더 정확하고 안정적인 발전량 예측이 가능하다.

Table 3. Performance Evaluation Table results of wind power prediction of wind farms for each model

Prediction Model	Metrics			
	MAE	scaled MAE	R <sup>2</sup>	RMSE
SVM	3300.8	11.0	0.71	4448.3
ANN	3566.4	11.9	0.70	4575.4
RF	3391.9	11.3	0.71	4447.5
XGB	3365.3	11.2	0.71	4434.9
S1	3289.9	11.0	0.71	4434.1
S2	3286.1	11.0	0.72	4426.2
S3	3228.4	10.8	0.72	4356.4

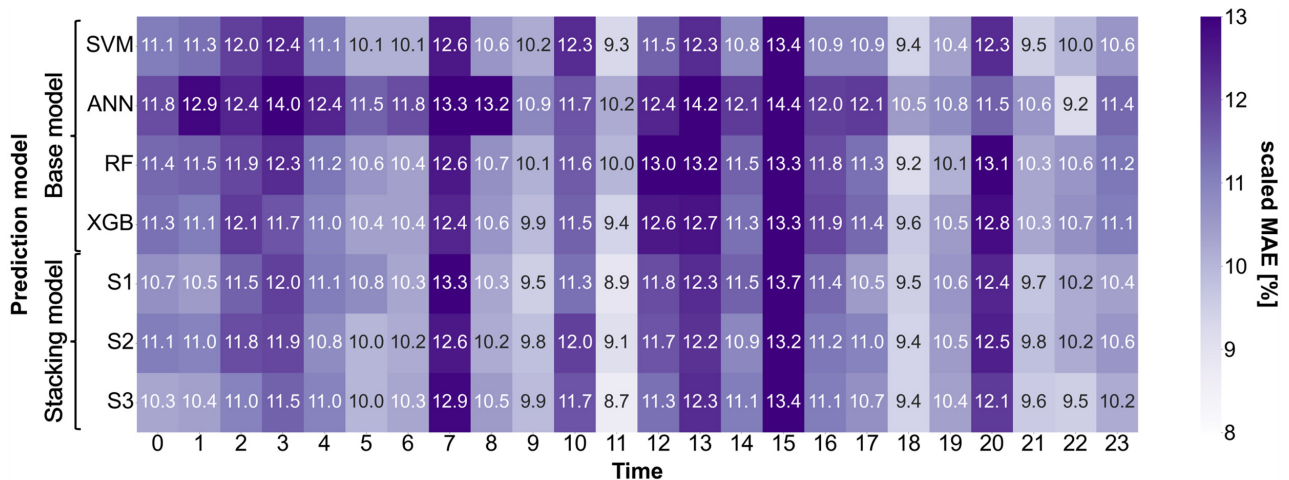


Fig. 8. Scaled MAE for each wind power prediction model for each forecast hour in LDAPS

## 5. 결론

본 연구에서는 기계학습 기반의 ANN, RF, XGB, SVM 모델과 이를 조합한 Stacking 모델을 이용하여 15개의 개별 터빈과 발전단지의 풍력 발전량을 예측했다. 기계학습 모델의 입력 데이터는 국지예보모델(LDAPS)의 60 m와 93 m의 풍속, 풍향 데이터를 사용했다. 성능 평가 지표는 총 4종으로 MAE, scaled MAE, R2, RMSE 등을 이용했다.

개별터빈의 scaled MAE를 비교한 결과 Stacking 모델은 모든 풍력터빈에서 기본모델(ANN, RF, XGB, SVM)보다 높은 예측 성능을 보였으며, 특히 후류 영향을 가장 많이 받을 것으로 예상되는 12호기 터빈에서 최대 0.7%의 scaled MAE를 개선했다. 풍력발전 단지의 발전량 예측 결과, Stacking 모델은 특히 고품속 영역에서도 기본모델보다 RMSE 성능을 개선하면서 우수한 예측 안정도를 보였다. 최종 성능지표를 산출한 결과, 모든 평가지표에서 Stacking 모델의 성능이 가장 우수하게 나타났으며, 그중에서도 모든 모델을 조합한 S3 모델이 가장 높은 예측 정확도를 보였다. 따라서 개별 풍력터빈 또는 풍력발전 단지 규모의 발전량 예측 과정에서 더 정확하고 안정적인 예측 결과를 얻기 위해서는 Stacking 모델의 적용을 고려할 필요가 있다.

## 감사의 글

이 논문은 2025학년도 제주대학교 교원성과지원사업에 의하여 연구되었음.

## References

- [1] International Renewable Energy Agency (IRENA), 2024, "WORLD ENERGY TRANSITIONS OUTLOOK 2024", IRENA, <https://www.irena.org/Publications/2024/Nov/World-Energy-Transitions-Outlook-2024>.
- [2] Global Wind Energy Council (GWEC), 2024, "GLOBAL WIND REPORT 2024", GWEC, [https://img.saurenergy.com/2024/05/gwr-2024\\_digital-version\\_final-1-compressed.pdf](https://img.saurenergy.com/2024/05/gwr-2024_digital-version_final-1-compressed.pdf).
- [3] Mingli, Z., Xu, H., Jianyuan, X., and Yun, T., 2010, "Study on application of the forecasting system for wind farm power", Proc. of the 2nd International Conference on Signal Processing Systems, 198-201.
- [4] Ouyang, T., Zha, X., and Qin, L., 2017, "A combined multivariate model for wind power prediction", Energy Convers. Manag., **144**, 361-373.
- [5] Ayodele, T.R., Jimoh, A.A., Munda, J.L., and Agee, J.T., 2012, "Challenges of Grid Integration of Wind Power on Power System Grid Integrity: A Review", Int. J. Renew. Energy Res., **2**(4), 618-626.
- [6] International Energy Agency (IEA), 2018, "World Energy Outlook 2018", <https://www.iea.org/reports/world-energy-outlook-2018>.
- [7] International Energy Agency (IEA), 2017, "Getting Wind and Solar onto the Grid", <https://www.iea.org/reports/getting-wind-and-solar-onto-the-grid>.
- [8] Korea Power Exchange (KPX), "Renewable Energy Generation Forecasting System", [https://der.kmos.kr/intro/fr\\_intro\\_view10.do](https://der.kmos.kr/intro/fr_intro_view10.do).
- [9] Optis, M. and Perr-Sauer, J., "The importance of atmospheric turbulence and stability in machine-learning models of wind farm power production", Renew. Sustain. Energy Rev., **112**, 27-41.
- [10] Breiman, L., 1996, "Bagging predictors", Mach. Learn., **24**, 123-140.
- [11] Heineremann, J. and Oliver K., 2016, "Machine learning ensembles for wind power prediction", Renew. Energy, **89**, 671-679.
- [12] Bühlmann, P., and Yu, B., 2010, "Boosting", WIREs Comp. Statis., **2**(1), 69-74.
- [13] Liu, W., and Jia, L., 2022, "Wind power prediction based on the stacking model of xgboost and random forest", Proc. of the 2022 IEEE 11th Data Driven Control and Learning Systems Conference (DDCLS), IEEE.
- [14] Luo, Z., Sun, Z., Ma, F., Qin, Y., and Ma, S., 2020, "Power optimization for wind turbines based on stacking model and pitch angle adjustment", Energies, **13**(16), 4158.
- [15] Moreno, S.R., da Silva, R.G., Ribeiro, M.H.D.M., Fraccanabba, N., Mariani, V.C., and Coelho, L.D.S., 2019, "Very short-term wind energy forecasting based

- on stacking ensemble”, Proc. of the 14th Brazilian Computational Intelligence Meeting (CBIC), Belem Brazil.
- [16] Barthelmie, R.J., Hansen, K., Frandsen, S.T., Rathmann, O., Schepers, J.G., Schlez, W., Phillips, J., Rados, K., Zervos, A., Politis, E.S., *et al.*, 2009, “Modelling and measuring flow and wind turbine wakes in large wind farms offshore”, *Wind Energy*, **12**(5), 431-444.
- [17] Sorensen, T., Nielsen, P., and Thogersen, M.L., 2006, “Recalibrating wind turbine wake model parameters—validating the wake model performance for large offshore wind farms”, Proc. of the European Wind Energy Conference and Exhibition, EWEA, [https://docs.wind-watch.org/wake-0693\\_Ewec2006fullpaper.pdf](https://docs.wind-watch.org/wake-0693_Ewec2006fullpaper.pdf).
- [18] Jeong, H.S., Kim, Y.H., and Choi, H.W., 2022, “Characteristics of Wind Environment in Dongbok·Bukchon Wind Farm on Jeju”, *New. Renew. Energy*, **18**(1), 1-16.
- [19] Kim, D.Y., Kim, Y.H., and Kim, B.S., 2021, “Changes in wind turbine power characteristics and annual energy production due to atmospheric stability, turbulence intensity, and wind shear”, *Energy*, **214**, 119051.
- [20] Wagner, R., Cañadillas, B., Clifton, A., Feeney, S., Nygaard, N., Poodt, M., Martin, C.S., Tüxen, E., and Wagenaar, J. W., 2014, “Rotor equivalent wind speed for power curve measurement-comparative exercise for IEA Wind Annex 32”, *J. Phys.: Conf. Ser.*, **524**, 012108.
- [21] Suárez-Cetrulo, A.L., Burnham-King, L., Haughton, D., and Carbajo, R.S., 2022, “Wind power forecasting using ensemble learning for day-ahead energy trading”, *Renew. Energy*, **191**, 685-698.
- [22] St Martin, C.M., Lundquist, J.K., Clifton, A., Poulos, G.S., and Schreck, S.J., 2016, “Wind turbine power production and annual energy production depend on atmospheric stability and turbulence”, *Wind Energy Sci.*, **1**(2), 221-236.
- [23] Agatonovic-Kustrin, S., and Rosemary Beresford., 2000, “Basic concepts of artificial neural network(ANN) modeling and its application in pharmaceutical research”, *J. Pharm. Biomed. Anal.*, **22**(5), 717-727.
- [24] Hsu, K.-L., Gupta, H.V., and Sorooshian, S., 1995, “Artificial neural network modeling of the rainfall-runoff process”, *Water Resour. Res.*, **31**(10), 2517-2530.
- [25] Zhang, J., and Wang, Y., 2008, “A rough margin based support vector machine”, *Inf. Sci.*, **178**(9), 2204-2214.
- [26] Breiman, L., 2001, “Random forests. Machine learning”, **45**, 5-32.
- [27] Freund, Y., and Schapire R.E., 1996, “Experiments with a new boosting algorithm”, Proc. of the International Conference on Machine Learning (ICML), **96**, 148-156, <https://cseweb.ucsd.edu/~yfreund/papers/boostingexperiments.pdf>.
- [28] Yang, L., and Shami, A., 2020, “On hyperparameter optimization of machine learning algorithms: Theory and practice”, *Neurocomputing*, **415**, 295-316.