



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

박사학위논문

풍력발전단지 에너지 생산량  
예측 고도화를 위한 입력 기상요인  
영향성 분석 및 기계학습 모델 평가

제주대학교 대학원

풍력특성화 협동과정

김 대 영

2022년 2월

# 풍력발전단지 에너지 생산량 예측 고도화를 위한 입력 기상요인 영향성 분석 및 기계학습 모델 평가

指導教授 金 範 錫

金 大 煥

이 論文을 工學 博士學位 論文으로 提出함

2021年 12月

金大煥의 工學 博士學位 論文을 認准함

審査委員長


委 員

委 員

委 員

委 員

고경남  
김성민  
배운해  
정지현  
고진환



濟州大學校 大學院

2021年 12月

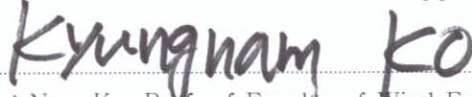
Analysis of the influence of meteorological factor  
and evaluation of machine learning models for  
advanced prediction of wind farm energy production.

Daeyoung Kim  
(Supervised by professor Bumsuk Kim)

A thesis submitted in partial fulfillment of the requirement for the  
degree of Doctor of Philosophy

2021. 12.

This thesis has been examined and approved.



Thesis director, Kyung-Nam Ko, Prof. of Faculty of Wind Energy Engineering



Thesis director, Bum-Suk, Kim, Prof. of Faculty of Wind Energy Engineering



Thesis director, Yoon-Hyeok Bae, Prof. of Dep. of Ocean System Engineering



Thesis director, Ji-hyun Jeong, Prof. of Mechanical Engineering



Thesis director, Jin-Hwan Ko, Prof. of Mechanical Engineering

December, 2021

Multidisciplinary Graduate School Program for Wind Energy  
Graduate School  
JEJU NATIONAL UNIVERSITY



# Abstract

Various prediction models have been proposed to precisely predict wind speed or power generation of wind turbines. However, it is difficult to propose a single prediction model that can be applied to all cases since wind energy has an intermittent nature. This characteristic means uncertainty and variability, and energy yield is dependent on the environmental conditions of each site where wind turbines are operated.

There are two techniques for predicting power generation of a wind turbine: a physical model-based and a statistical model-based approaches. A statistical model constructs a model based on already accumulated data, which analyzes the quantitative correlation between the data of wind power generation facility and meteorological factors. Currently, statistical model tends to transition to more improved approaches called machine learning and artificial intelligence models.

Input features generally used in the prediction of wind turbine power generation using machine learning algorithms are wind speed, wind direction, temperature, pressure, relative humidity, while atmospheric stability and turbulence characteristic values are rarely used. However, since atmospheric stability and turbulence characteristic values can significantly affect the actual output performance of a wind turbine, it is necessary to construct a prediction model using these factors and evaluated the prediction accuracy of the constructed model. Moreover, further studies on detailed role and scope of these factors on energy production need to be conducted as there are insufficient research results suggesting the difference in annual power generation from a wind turbine or wind farm scale due to the changes in atmospheric stability and turbulence characteristic values.

There are three objectives of this study to resolve these issues. First, atmospheric stability, turbulent kinetic energy, turbulence intensity, and wind speed shear factor for an onshore wind farm, a target site of this study, are classified by regime to analyze the effect on the output and AEP of a single wind turbine (and multiple wind turbines). Second, prediction contribution of individual meteorological factors was presented during the energy production prediction process in the wind farm using four machine learning algorithms and 13 meteorological factors. Finally, the prediction accuracy of the model is evaluated after constructing energy production prediction models using atmospheric stability and turbulence characteristic values that can be applied to wind farms.

For a single wind turbine, high AEP is shown when regime of atmosphere is medium instability, high TI and TKE. Although the wind turbulence is considered to have a negative effect on wind turbine operation, conditions with weakened turbulence and a certain level of turbulence is turned out to be more advantageous than fully developed turbulent flow or the absence of turbulence in terms of wind turbine power generation. For wind farms, the difference in annual power generation for each regime according to the atmospheric stability is approximately 5-7%. More specifically, when the atmosphere is stratified into weak instability and stability regimes, the output differences between wind turbines are 25% and 45%, respectively. The output differences are confirmed to be significant in terms of statistical point of view. In the evaluation of the accuracy of prediction model for wind farm power generation using machine learning, the models constructed using atmospheric stability and turbulence characteristic values show high prediction accuracy. In particular, input features that showed the second highest prediction contribution following wind speed during the prediction process are turbulent kinetic energy, turbulence dissipation rate, and turbulence intensity. These features are analyzed to provide very useful information for improving

the accuracy of the prediction model.

The results of this study can be used for the advancement of wind turbine power production forecasting technology. Improved forecasting technology enables efficient operation of highly variable wind energy source, practically helping secure the stability and economic feasibility of wind power generation facilities.

# 목 차

List of Figures .....	iii
List of Tables .....	v
Nomenclature .....	vi
I. 서론 .....	1
1.1 연구 배경과 동향 .....	1
1.1.1 풍력터빈 출력에 영향을 미치는 환경 조건 .....	1
1.1.2 대기상태와 풍력터빈의 후류 회복성 .....	3
1.1.3 기계학습 알고리즘을 이용한 풍력터빈 에너지 생산량 예측 .....	6
1.2 연구 목적 .....	8
II. 풍력 발전단지 환경 조건과 기상자료 수집 .....	11
2.1 측정사이트와 관측장비 구성 .....	11
2.2 기상요인과 유효자료 .....	15
2.2.1 기상요인 종류와 레짐 분류 .....	15
2.2.2 자료 품질 관리 .....	22
III. 기계학습 모델 구축과 성능 평가 방법 .....	27
3.1 연간발전량과 정규화된 출력 계산 .....	27
3.2 통계검정 .....	29
3.3 모델링과 검증 .....	30
3.3.1 기계학습 알고리즘 .....	31
3.3.2 하이퍼파라미터 최적화와 교차 검증 .....	32
3.4 기상요인 예측 기여도 계산 .....	34
3.5 예측 모델의 종류와 구성: 대기안정도와 난류 특성값의 활용 .....	35
IV. 풍력 발전단지 에너지 생산량 예측 정확도 평가 .....	38
4.1 기상요인에 의한 풍력터빈의 출력 특성과 연간발전량 변화 .....	38
4.1.1 기상요인 분포 특성 .....	38

4.1.2 단일 풍력터빈의 연간발전량 차이 .....	50
4.1.3 풍력 발전단지의 연간발전량 차이 .....	56
4.2 에너지 생산량 예측 모델 정확도 분석 .....	61
4.2.1 기계학습 알고리즘의 예측 성능 .....	61
4.2.2 기상요인 예측 기여도 비교 분석 .....	64
4.2.3 기상요인 예측 기여도 비교 분석 .....	74
V. 결론 .....	77
5.1 요약 및 결론 .....	77
5.2 추후 연구 .....	79
참고문헌 .....	81
부록 .....	81

# LIST OF FIGURES

Fig. 1.1 Environmental conditions affecting wind turbines .....	3
Fig. 1.2 Schematic of the wake structure induced by the interaction of the wind turbine with the wind field entering the turbine .....	5
Fig. 1.3 Groups of AI approaches used for energy demand response .....	7
Fig. 1.4 Flow chart of this study .....	10
Fig. 2.1 Information on study site .....	12
Fig. 2.2 A view of the 80m tubular-type meteorological mast installed at the Dongbok-Bukchon wind farm in Jeju Island .....	13
Fig. 2.3 Turbulent energy spectrum based on the Kolmogorov hypothesis .....	18
Fig. 2.4 Energy spectrum of the turbulent-velocity component .....	20
Fig. 2.5 Frequency ratio according to Ri .....	21
Fig. 2.6 Turbulence intensity (TI) distribution according to the changes in wind direction and wind speed. ....	23
Fig. 2.7 Valid power data for WTG No. 15 .....	24
Fig. 3.1 Comparison of wind speed data measured by 80m high meteorological mast and 80m high wind turbine .....	27
Fig. 3.2 Flow chart for building and applying the predictive model of atmospheric stability and turbulence parameters .....	36
Fig. 4.1 Scatter diagram (top) and box plot (bottom) of wind shear exponent (WSE) according to the change in atmospheric stability .....	39
Fig. 4.2 Scatter diagram (top) and box plot (bottom) of wind speed according to the change in atmospheric stability .....	40
Fig. 4.3 Scatter diagram (top) and box plot (bottom) of turbulence intensity (TI) according to the change in atmospheric stability .....	41
Fig. 4.4 Scatter diagram (top) and box plot (bottom) of vertical wind according to the change in atmospheric stability .....	43
Fig. 4.5 Scatter diagram (top) and box plot (bottom) of turbulent kinetic energy (TKE) according to the change in atmospheric stability .....	44

Fig. 4.6 Vertical wind according to the horizontal wind for each atmospheric stability condition .....	46
Fig. 4.7 Scatter diagram (top) and box plot (bottom) of turbulent dissipation rate ( $\varepsilon$ ) according to the change in atmospheric stability .....	48
Fig. 4.8 Turbulence dissipation rate ( $\varepsilon$ ) curve according to the horizontal wind speed for each atmospheric stability regime .....	50
Fig. 4.9 Scatter plots (left column) and power curves (right column) according to the regime using the power data of the 15th wind turbine .....	52
Fig. 4.10 Power differences between regimes of atmospheric factors .....	54
Fig. 4.11 Relative errors of AEP by the regime of atmospheric factors .....	56
Fig. 4.12 Probability distribution of the normalized power according to the classified atmospheric regimes .....	57
Fig. 4.13 Heatmap: (a) normalized power in individual WTGs by atmospheric stability regime and (b) statistical test of the difference in the normalized power .....	59
Fig. 4.14 Mean power curve for each regime using power data for all WTGs .....	60
Fig. 4.15 Relative difference in the annual energy production (AEP) of the wind farm according to the atmospheric regimes .....	61
Fig. 4.16 Normalised power by model according to diurnal cycle .....	62
Fig. 4.17 RMSE of 10-min average power and daily energy production prediction of wind farm according to input feature group and machine learning model .....	64
Fig. 4.18 Summary plot of input features using SHAP algorithm. 10-min average power and daily energy production prediction results of wind farm using LGBM .....	66
Fig. 4.19 The absolute influence of the SHAP value .....	67
Fig. 4.20 Force plot of the 148th instance (freestream case with wind direction of 294.7°, corresponding to prevailing wind direction) using SHAP algorithm .....	70
Fig. 4.21 Force plot of the 156th instance (downstream case with wind direction of 193.1°) using SHAP algorithm .....	70

# LIST OF TABLES

Table. 2.1 Types and specifications of sensors installed on the meteorological mast for collection of weather data .....	14
Table. 2.2 Definition of thresholds for classification of stability regimes .....	21
Table. 2.3 Number of valid data and frequency ratio with regime of meteorological factors	22
Table. 3.1 Summary of classified input feature groups and meteorological factors .....	30
Table. 3.2 Optimized hyperparameter settings for each ML algorithm .....	32
Table. 3.3 Prediction performance evaluation index for ML algorithms .....	33
Table. 3.4 Models for evaluating the prediction accuracy of DBWF energy production .....	37
Table. 4.1 Results of 10-minute average power prediction .....	75
Table. 4.2 Results of daily energy production prediction .....	76



# Nomenclature

Symbol	Description	Unit
AEP	Annual energy production	
$D_u(r)$	The valid second-order structural function for the spatial separation( $r$ ) in the flow direction within the range of inertia	$[m^2/s^2]$
$D_u(\tau)$	Second-order structural calculated using horizontal speed for time increment $\tau$	$[m^2/s^2]$
F	Frequency	$[s^{-1}]$
$F(V)$	The rayleigh cumulative probability distribution function for wind speed	
g	Gravitational acceleration	$m/s^2$
N	Number of bins	
$N_h$	Number of hours in one year $\approx 8760$ [h]	
$N_i$	Number of 10 min data sets in wind speed bin i	
$P_{free}$	Power output of wind turbine located in freestream	[kW]
$P_i$	Normalized and averaged power output in bin i	
$P_{nor}$	Normalized power output	[kW]
$P_{wake}$	Power output of wind turbine located in downstream	[kW]
Ri	Richardson number	
$S_u(f)$	Power spectral density	$[m^2/s]$
T	Temperature	$^{\circ}C$
TI	Turbulence intensity	
TKKE	Turbulent kinetic energy	$m^2/s^2$
U	Wind speed	m/s
u	Stream wise velocity component	m/s
$u'$	Deviation from mean stream wise velocity	m/s
V	Wind speed	m/s
v	Lateral wise velocity component	m/s
$v'$	Deviation from mean lateral wise velocity	m/s
$V_1$	Wind speed at $Z_1$ height	m/s
$V_2$	Wind speed at $Z_2$ height	m/s
$V_{ave}$	Annual mean wind speed	m/s
$V_i$	Standardized average wind speed in bin i	m/s
$\bar{V}$	10-minute averaged wind speed	m/s
WSE	Wind shear exponent	
w	Vertical velocity component	m/s
$w'$	Deviation from mean vertical velocity	m/s
Z	measuring point	m
$\alpha$	Kolmogorov constant	
$\varepsilon$	Turbulent dissipation rate	$m^2/s^3$
$\sigma$	Standard deviation	m/s
$\Delta T$	Temperature difference at $\Delta z$	$^{\circ}C$
$\Delta z$	Difference between measuring points	m

# I. 서론

## 1.1 연구 배경과 동향

### 1.1.1 풍력터빈 출력에 영향을 미치는 환경 조건

풍력자원 평가의 최종목표는 정확한 에너지 생산량 예측이다[1]. 에너지 생산량을 예측하기 위해서는 풍력터빈의 허브높이 부근 풍속 정보와 출력 곡선이 필요하다. 풍력 발전단지 개발 예정지의 환경 조건과 풍력터빈의 출력 특성이 에너지 생산량 산정에 직접적인 영향을 미치기 때문이다. 따라서 에너지 생산량 계산과정에서 예측 오차를 줄이기 위해서는 환경 조건에 따른 풍력터빈의 정확한 출력 곡선이 요구된다[2].

풍력터빈의 출력에 영향을 미치는 환경 요인으로는 크게 지형, 지표 마찰, 장애물, 기상요인 및 기타 인근 풍력터빈의 후류 등으로 분류할 수 있다(Fig. 1.1)[3]. 이 중에서 기상요인은 바람 센서를 통해 1차적으로 측정되는 풍속, 풍향, 온도, 습도, 압력과 2차적으로 계산되는 대기안정도와 난류 특성값인 난류운동에너지(Turbulent kinetic energy, TKE), 난류강도(Turbulence intensity, TI), 난류 소산율(Turbulence dissipation rate, TDR,  $\epsilon$ ) 그리고 기타 매개변수인 풍속전단지수(Wind shear exponent, WSE,  $\alpha$ ), 풍향 순전(Wind veering) 등으로 구분할 수 있다. 특히, 추가적인 계산을 통해 산출되는 기상요인이 풍력터빈 출력에 미치는 영향을 파악하기 위해 몇몇 연구들이 수행되었다[4 - 8]. EWTW (ECN Wind turbine Test station Wieringermeer) 사이트에서 실시한 연구에서는 5~13m/s 풍속 구간에서 WSE 차이에 따라 최대 30%의 출력 표준편차를 보였다[9]. Horns Rev 지역의 Nysted 해상풍력발전단지에서 수행된 연구에서는 TI가 1% 변화할 때, 출력은 0.98~1.40%의 변동성을 보였다[10]. 이외에도 수직적 난류강도( $I_w$ )와 TKE, 풍향 순전과 같은 요인들이 풍력터빈의 출력 특성에 미치는 연구가 수행되었다[11 - 13].

실제 사이트에서는 다양한 대기상태가 존재한다[14]. 사이트마다 정도의 차이는 있겠지만, 일반적으로 태양복사 에너지에 의해 유발된 강한 일주기 변화를 경험하게 된다. 특히, 대기의 안정도는 일변화 동안 열적 요인에 의해 중립 이외에 안정 또는 불안정과 같은 상태가 나타난다. 대기안정도는 윈드시어와 난류의 생성·소멸 등에 영향을 준다. 이러한 영향은 바람장에 반영되어 풍력터빈의 회전면적으로 유입되고 최종적으로 터빈의 출력에 영향을 미친다[11,15]. 따라서 대기안정도를 중립상태로 가정한 제조사의 출력 곡선(Manufacture's power curve, MPC)은 실제 사이트에 설치된 풍력터빈의 출력 곡선과 차이를 보일 수밖에 없다[16,17]. 이 차이는 연간발전량(Annual Energy Production, AEP) 산정과정에서 오차로 이어진다.

바람장에 영향을 주는 기상요인은 열적 상태에 기반하여 그 특성이 변화하기 때문에 연구 결과들은 지역마다 차이를 보인다. 우선, 대기가 안정 상태일 때 풍력터빈이 우수한 출력 성능을 나타내는 연구 결과는 다음과 같다. Western North America 지역에서 수행된 연구는 대기가 안정 상태일 때, 불안정 상태 더 출력이 약 15% 높게 나타났다[18]. 또한 US Great Plains, Midwest 지역의 풍력발전단지에서는 난류가 증가할수록 AEP은 감소하였다[12]. 그리고 Boulder, Colorado 지역에서 수행된 연구는 대기상태에 따라 와이블 분포를 산출한 후에 AEP를 계산하여 그 결과를 비교하였다. 결과는 TI와 대기안정도가 저 레짐(Regime)일 때, 고 레짐보다 높은 발전량을 보였다[19].

반면에 대기가 불안정 레짐일 때 높은 출력 성능을 보이는 연구 결과도 있다. 독일의 Alpha ventus 풍력발전단지에서 대기상태에 따라 풍력터빈 출력을 대상으로 후류 영향이 없을 때(non-wake), 단일 후류일 때(single-wake) 및 중첩 후류일 때(double-wake)로 분류하여 분석하였다. 이 중에서 후류 영향이 없는 단일 풍력터빈의 경우, 전체적으로 고 TI가 저 TI 보다 약 15% 높은 출력을 보였고, 특정 풍속구간에서는 최대 20% 높은 출력 차이를 보였다[5]. Vanderwende and Lundquist(2012)는 북아메리카의 로키산맥 동쪽에 위치한 풍력발전단지에 134개 풍력터빈의 측정자료를 이용하여 연구를 수행하였다. 결과는 약 10m/s의 동일한 풍속 구간이라도 WSE와 대기안정도(리처드슨 수를 이용)가 불안정 레짐일 때, 기타 레짐에 비해 약 87kw의 높은 출력이 나타남을 확인하였다[18]. 또한

해상풍력발전단지 Egmond aan Zee(OWEZ)와 North Hoyle에서 풍력터빈의 출력은 매우 불안정한 대기상태가 기타 대기상태에 비해 약 10~20% 높게 나타났 다[20].

풍력 부문의 국제전기표준위원회(IEC 61400-12-1)에서는 각 사이트의 대기안 정도 특성이 풍속 측정과 풍력터빈의 실질적인 출력 성능에 상당한 영향을 미칠 수 있음을 언급하고 있다[21]. 하지만 여전히 대기를 중립상태로 가정하고 있다. 이는 단지 지표면 마찰에 의해 본질적으로 발생하는 기계적 난류만을 고려하고, 가열된 지표면에 의해 유발된 대류 난류는 반영되지 않고 있음을 의미한다. 풍속 전단, 풍향 순전 및 난류 특성값들은 모두 대기안정도의 함수이기에 이를 고려하 는 것은 풍력터빈의 보다 엄밀한 출력 특성을 산출할 수 있음을 시사한다.



Fig. 1.1 Environmental conditions affecting wind turbines: meteorological factors (wind speed, wind direction, temperature, humidity, pressure, etc), topography, surface roughness, turbulence and wakes of nearby wind turbines.

### 1.1.2 대기상태와 풍력터빈의 후류 회복성

풍상측 바람에서 운동에너지를 추출하면, 풍하측에는 보다 감소한 운동에너지 가 잔존한다[14]. 운동량 추출과정에서 풍력터빈 블레이드는 회전 면적으로 유입 되는 바람을 주기적으로 통과하고, 이때 블레이드의 회전 거동은 강건한 평균 흐름에서 소용돌이와 무작위성 난류를 발생시킨다[22]. 즉, 유입 유동장의 풍속 감소와 난류 생성을 유발하여 그 특성을 변화시킨다. 변화된 유동장은 풍력터빈의 후방으로 수송되며 우리는 이를 후류라 부른다(Fig. 1.2 참조). 일반적으로 후류

는 전·후방 풍력터빈 간에 약 10~20%의 출력 차이를 야기시킨다[23,24]. 후류 영역에서 활용 가능한 운동에너지의 이해는 풍력터빈 또는 풍력 발전단지의 에너지 생산량 추정에 있어 매우 중요하다[25,26]. 일반적으로 풍력터빈 후방은 2개의 영역인 후류 영역과 그 주변부의 자유 유동 영역으로 구분된다. 후류 영역은 느린 흐름을 자유 유동 영역은 빠른 흐름을 보이며, 두 흐름은 비 동질한 유동장을 형성한다. 이 이질적 유동장 사이의 경계면에서 속도차이가 발생하며, 블레이드의 회전운동과 마찬가지로 이 속도 차이는 소용돌이를 발생시키는 또 하나의 주요 요인이다. 생성된 난류 소용돌이는 주류방향으로 수송되며, 이 과정에서 성격이 다른 두 유동장의 경계층 접촉면은 점점 확장된다. 확장되는 접촉면은 난류 소용돌이 구조의 성장과 진전을 통해 혼합층으로 발달하고, 혼합층은 최종적으로 동질한 유동장으로 전이된다[27]. 이와 같은 일련의 후류 구조는 에너지·운동량 보존법칙에 기인한다[28]. 따라서 에너지 생산량 추정에 있어 풍력터빈 후방에서의 운동에너지의 이해는 매우 중요하다.

대기 난류는 후류 흐름에서 상반된 역할을 수행할 수 있다. 이질적 유동장 사이의 상호작용을 억제하여 후류 회복을 저해하거나 상호작용을 촉진하여 후류 회복에 기여하는 역할이다[29]. 풍력공학 분야에서는 대기 경계층의 성층화 상태를 대기안정도로 표현하여 활용된다. 대기안정도는 열적 안정도를 의미하며, 풍력터빈의 출력 성능에 유의미한 영향을 주는 요인이다[5,12,16,18 - 20,30]. 풍력터빈으로 유입되는 유동의 평균 전단과 TI가 열적 안정도 변화에 기인하기 때문이다[14,31 - 33]. 다수의 연구에서 대기안정도가 대류 경계층일 때, 중립 경계층과 안정 경계층 보다 빠른 후류 회복과 강한 굽이침을 보이는 것으로 보고된다[31 - 35]. 상대적으로 높은 TI를 보이는 대류 경계층(Convective boundary layer, CBL)에서 난류 혼합과 유동 유입이 강화 양상을 보이기 때문으로 분석된다[32,33].

풍력터빈 후류에서 나타나는 소용돌이의 성장과 소멸의 특성을 제시할 때, 일반적으로 난류 에너지 소산율을 이용한다[36 - 38]. 풍력터빈의 후류 길이와 범위는  $\varepsilon$ 에 강한 의존성을 보이기 때문이다. 이와 관련하여 미 국립 해양대기청(National Oceanic Atmosphere Administration, NOAA)에서는 도플러 라이다를 이용하여, 풍력터빈 근처의 공간적 바람 구조를 분석하였다. 풍속의 세기와 대기 난류에 따라 운전 중인 풍력터빈의 후류 영역에서 27~74%의 풍속 저감을 보였다.

또 120~1,180m의 후류 길이 변화를 보였다. 특히, 고풍속에서  $\varepsilon$ 이 2배 증가( $0.0066\text{m}^2/\text{s}^3$ 에서  $0.013\text{m}^2/\text{s}^3$ )할 때, 후류 길이는 680m에서 340m로 반감되었다[38]. NWTC의 테스트 사이트에서도 연구가 수행되었다.  $\varepsilon$ 은 후류 영역과 비 후류 영역에서 뚜렷한 규모 차이를 보이며, 수평 풍속과 TI 변화에 따라 후류 영역의  $\varepsilon$ 이 약 1~2 차수(거듭제곱 법칙의 지수) 높은 수준을 보이는 것으로 분석되었다 [22].

상기에 언급한 연구들은 대기의 성층화 상태와  $\varepsilon$ 의 성질이 후류 흐름에 영향을 미친다는 것을 보여준다. 대기의 중립상태는 현실에서 거의 발생하지 않으며 [30], 실제 사이트에서는 가열된 지표면에 의해 대류 난류가 발생한다. 이를 감안하면, 대류 난류와 후류 흐름 사이의 상호작용에 기인한 운동에너지 교환은 반영되지 않음을 의미한다. 후류 역학에 대기안정도와  $\varepsilon$ 이 고려되어 분석된다면, 후류 효과를 보다 엄밀한 수준으로 분석할 수 있다. 이는 대기의 성층화 상태에 따른 후류 회복성의 세분화된 이해를 의미하며, 후류 모델 개선, 풍력 발전단지 에너지 생산량 예측의 정확도 향상으로 이어질 수 있음을 시사한다.

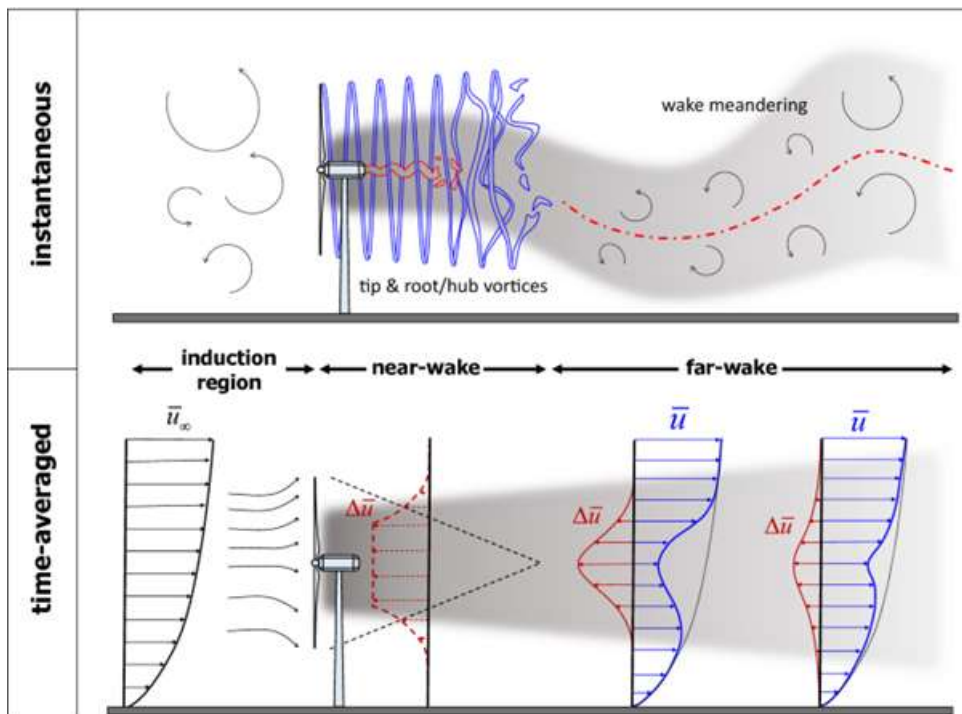


Fig. 1.2 Schematic of the wake structure induced by the interaction of the wind turbine with the wind field entering the turbine. Depicted are the most characteristic instantaneous (top) and time-averaged (bottom) flow features [30].



### 1.1.3 기계학습 알고리즘을 이용한 풍력터빈 에너지 생산량 예측

풍력 분야에서는 풍속 및 발전량의 보다 엄밀한 예측을 위해, 다양한 접근방식의 예측 모델들이 제시되고 있다[39]. 하지만, 모든 경우에 적용 가능한 단 하나의 예측 모델을 제시하기에는 힘든 측면이 있다. 풍력 에너지는 원천적으로 간헐적 특성을 내포하기 때문이다[40]. 간헐적 특성은 불확실성과 변동성을 의미하며, 풍력 발전설비가 운영되는 각 사이트의 환경 조건에 의존성을 보인다. 외부환경 조건은 지형 복잡도와 지표면 거칠기 뿐만 아니라, 다양한 시공간적 규모에서 나타나는 대기상태도 포함된다. 특히, 기상요인과 바람장의 상호작용 속에서 풍속 또는 발전량에 대해 예측하기 힘든 비선형적 특징들이 유발된다.

일반적으로 풍속과 발전량 예측을 위한 접근법은 크게 물리적 모델 기반 접근 방식과 통계적 모델링 기반 접근방식으로 나눌 수 있다[41]. 물리적 모델은 풍력 발전단지의 현장 조건을 상세한 물리적 모사를 통해 모델링하는 방식이다[42 - 46]. 풍력 발전단지의 지형 조건, 풍력터빈의 출력 곡선과 레이아웃을 고려할 뿐만 아니라, Numerical Weather Prediction(NWP) 데이터의 refinement 및 대기 경계층 하부의 타겟 영역에 대한 다운 스케일링을 적용하여 시뮬레이션하는 방식이다. 통계적 모델은 이전에 기록된 데이터를 기반으로 통계 모델을 구축하는 방식이다[47 - 51]. 이미 운영되어 수집 중인 풍력 발전설비의 자료(출력·발전량 자료)와 대기 변수 자료(NWP 시스템 자료 또는 현장 측정 자료)간의 정량적 상관성을 분석하는 것이 핵심이다.

물리적 모델 기반 접근방식은 복잡한 기상 예측 모델을 바탕으로 풍력발전 설비의 발전량을 계산한다. 계산과정에서 시간 소비가 심하고, 대용량의 컴퓨팅 자원이 요구된다. 이러한 제약조건들로 인해 국부적인 지역의 풍속 또는 풍력 발전단지의 발전량 예측에 있어, 통계적 모델링 접근방식이 보다 선호되는 경향이 있다[39,41]. 현재 통계적 모델은 보다 정확한 풍력 에너지를 예측하기 위해, 전통적 접근법(autoregressive model, AR; moving average model, MA; autoregressive integrated moving average model, ARIMA)에서[52 - 54] 기계학습(Machine Learning, ML) 또는 인공지능 모델이라 불리는 보다 개선된 접근법(support vector machines, SVMs; random forests, RFs; gradient boosting models, GBMs; artificial neural networks, ANNs; )으로 전환되는 추세이다[48,50,51,55 - 57](Fig.

### 1.3 참조).

최근 ML 기반의 모델들은 높은 예측 성능을 보인다. 반면에 내부 알고리즘은 복잡한 체계로 구성되어 알고리즘의 의사결정 과정은 불투명한 편이다. 입력 자료에 따른 예측 결과물의 도출에 있어, ML 알고리즘의 거동과 사고 과정의 온전한 이해가 힘들다. 이는 ML 모델의 결과물을 통해 합리적 접근방법과 인사이트를 얻기 힘들다는 문제를 야기시킨다[58]. 특히, 앙상블 기법과 신경망 기법을 기반으로 한 ML 모델에서 이러한 단점은 더욱 두드러진다[59,60]. 이 점은 풍력 발전단지 발전량과 다수의 기상요인 사이에 상호 연관성이 충분히 제시되지 않았다는 점과 혼재되어 있다. 이에 따라, ML 모델의 의사결정과정에서 기상요인들의 영향력에 대한 전체적인 기본 틀이 파악되지 않은 채 여전히 블랙박스로 남아있는 실정이다.

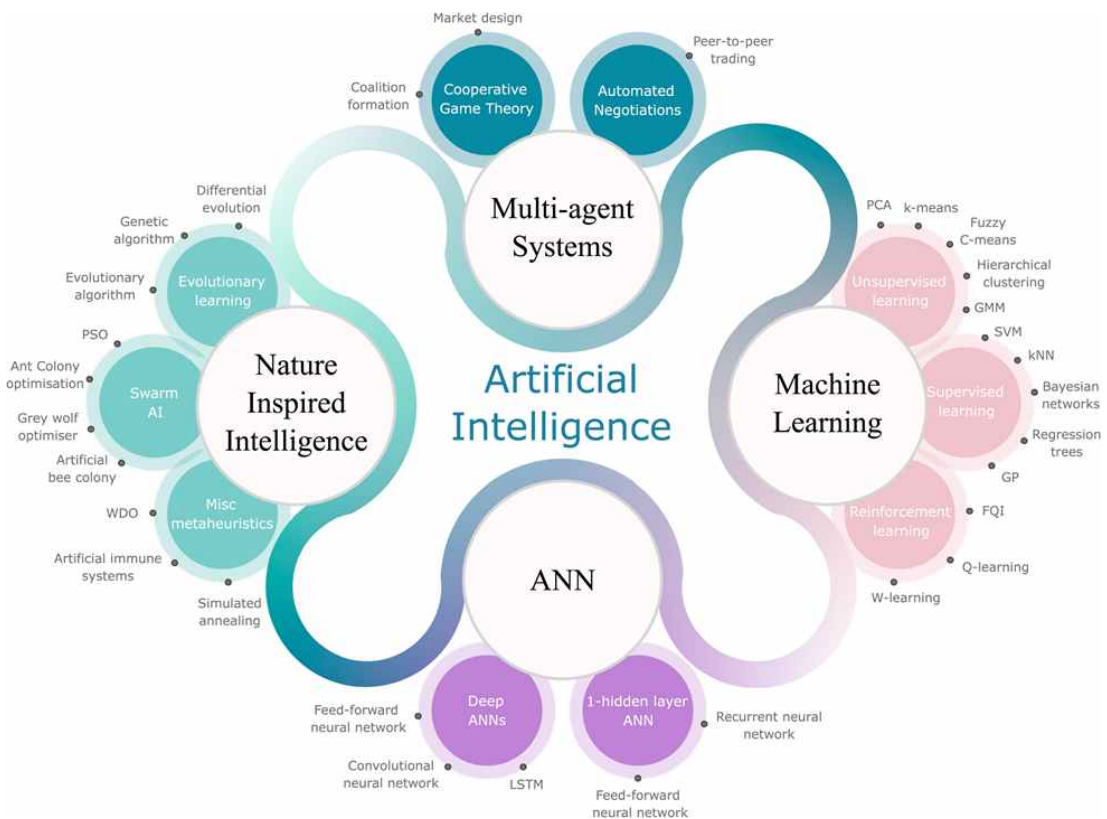


Fig. 1.3 Groups of AI approaches used for energy demand response [61]



## 1.2 연구 목적

상기에 수행된 연구의 조사 결과 다음과 같은 세 가지 문제점이 있다. 우선, 1.1절에서 언급한 연구들은 기상요인을 몇 가지 레짐으로 분류하였고 분류된 레짐에 따라 풍력터빈의 출력 곡선을 비교 분석하였다. 하지만, 연구 결과는 레짐과 풍력터빈 출력 특성 사이의 일반적인 상관관계를 제시하기에는 상충하는 부분들이 존재한다. 특히, 대기안정도와 풍력터빈 출력 사이의 보편적 상관성을 확인하기에는, 여전히 연구가 불충분하고 논쟁의 여지가 있다. 또한, 대기안정도는 풍력터빈의 에너지 변환 과정에 영향을 미칠 수 있음을 인지하고 있지만, 대기안정도 변화에 기인한 AEP 차이를 제시하는 연구 결과물은 거의 없는 실정이다.

다음, 1.1.2절에서 언급한 연구들은 풍력터빈의 후류·비 후류 영역에서 풍속과  $\varepsilon$  규모에 따른 후류 길이를 분석하였다. 또한 대기안정도 레짐에 따른 풍속 저감을 다루었다[2,17,18,20 - 22,26]. 하지만, 이 연구들은 단일 풍력터빈 대상 또는 수치 모의 기반의 연구 방법을 채택하고 있다. 풍력 발전단지 규모에서 실측자료를 이용한 연구 결과는 여전히 부족하다. 특히, 대기안정도 레짐에 따라 지배적으로 나타나는  $\varepsilon$ 의 성질과 풍력 발전단지 에너지 생산량에 미치는 상세한 역할이나 범위는 보다 연구될 필요성이 있다.

마지막으로 1.1.3절에 언급된 대다수의 풍력 발전단지 발전량 예측 연구에서 모델의 입력값으로 풍속, 풍향, 대기압, 온도 및 습도만을 고려하고 있다[8,11 - 13,23]. 대기안정도와 난류 특성값이 입력 피처로 활용될 때, 그 영향력에 관한 연구는 여전히 미진하다[1]. 즉, ML 알고리즘의 토대 위에 각 기상요인의 예측 기여도 수준을 면밀히 탐구한 연구가 불충분한 상황이다.

상기의 문제점을 해결하기 위한 본 연구의 목적은 다음과 같다:

- 대기안정도, 난류운동에너지, 난류강도, 풍속전단지수를 레짐 별로 분류하여 단일 풍력터빈의 출력과 AEP에 미치는 영향을 제시한다.
- 대기안정도를 기반으로 풍력 발전단지의 AEP 차이를 제시하고, 통계검정을 통해 이 차이가 유의미한 차이인지를 분석한다.
- 4개 ML 알고리즘과 13개 기상요인을 이용하여 풍력 발전단지 에너지 생산량 예측 모델을 구축하는 과정에서 개별 기상요인의 예측 기여도를 분석한

다.

- 최종적으로 대기안정도와 난류 특성값을 이용한 풍력 발전단지 에너지 생산량 예측 모델의 정확도를 평가한다.

상기의 연구 목적을 달성할 경우, 기상요인과 풍력터빈 출력 또는 풍력 발전단지 발전량 사이의 보다 엄밀한 상관성을 확인할 수 있다. 또한, ML을 이용한 발전량 예측 모델 구축과정에 기상요인들의 예측 기여도를 파악하여, 연구자로 하여금 모델 개선 방법을 선택함에 있어 효과적인 의사결정을 가능하게 한다. 이는 개선된 에너지 생산량 예측기법을 의미하며, 풍력 발전단지의 설계·운영 단계에서 보다 높은 수준의 안정성과 신뢰성을 확보할 수 있다. 최종적으로 풍력발전산업의 재정적 위험성을 낮추고, 재정적 확실성에 기여하는 유의미한 혜택을 기대할 수 있다.

본 연구는 총 2단계로 구성하였다(Fig. 1.4 참조). 1단계에서는 기상요인의 레짐 변화에 따른 단일 풍력터빈의 AEP 차이를 평가하였다. 세부적으로 기술적 통계 기법을 이용하여 기상요인들의 분포 특성을 분석하였고, 레짐에 따른 상승류·하강류 분석 및 출력 곡선 차이를 제시하였다. 다음, 풍력 발전단지를 대상으로 레짐에 따른 AEP 차이를 평가하였다. 이를 위해 전체 15기 풍력터빈의 출력 곡선을 산출하고, 풍속의 확률분포(레이리 분포)를 이용하여 AEP를 계산하였다. 이때 레짐별로 계산된 AEP의 비교 분석을 통해 그 차이를 제시하였다.

2단계에서는 4개 ML 알고리즘과 13개 기상요인을 이용하여 예측 모델을 구축하고, 그 과정에서 SHapley Additive exPlanations (SHAP) 알고리즘을 이용하여 입력 피쳐로 사용된 기상요인의 예측 기여도를 분석하였다. 최종적으로 대기안정도와 난류 특성값이 고려된 풍력 발전단지 에너지 생산량 예측 모델의 정확도를 평가하였다.

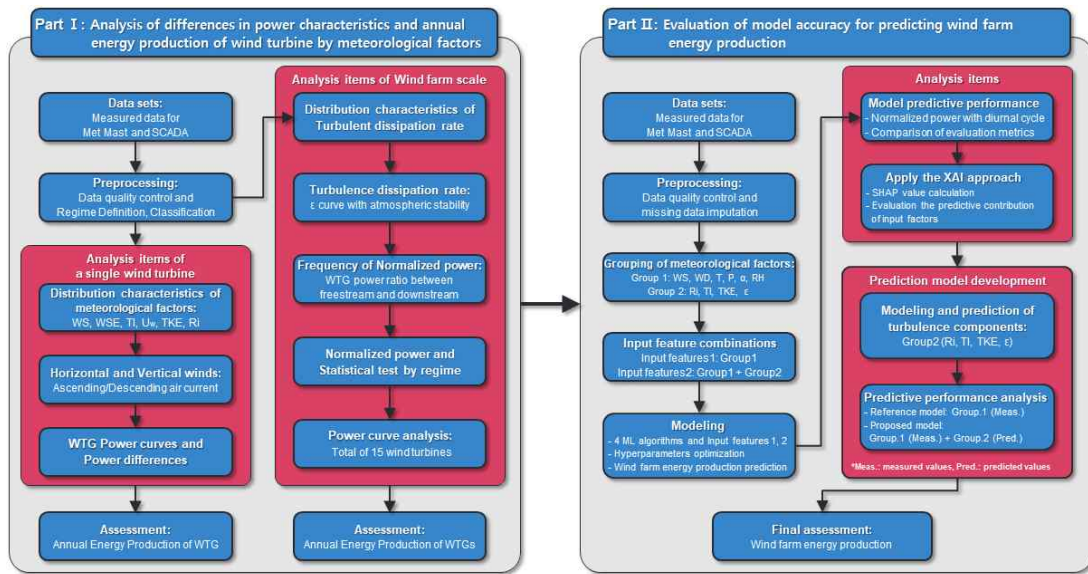


Fig. 1.4 Flow chart of this study. It consists of two steps. Part I: Evaluation of the influence of atmospheric factors on annual energy production and wake effect by the regime and Part 2: Evaluating the predictive contribution of meteorological factors and developing an estimator

본 논문은 다음과 같이 총 5장으로 구성되어있다.

2장 “풍력 발전단지 환경 조건과 기상자료 수집”에서는 측정사이트의 환경 조건, 관측장비, 수집된 데이터의 품질관리, 유효자료 및 기상요인의 종류 등을 기술하였다.

3장 “기계학습 모델 구축과 성능 평가 방법”에서는 연간발전량과 정규화된 출력 계산 방법, 통계검정 기법, 기계학습 알고리즘, 교차 검증 방법 및 예측 모델의 종류와 구성을 기술하였다.

4장 “풍력 발전단지 에너지 생산량 예측 정확도 평가”에서는 레짐별 단일 풍력 터빈의 AEP 차이와 풍력 발전단지 규모(15기 풍력터빈)에서의 AEP 차이를 분석하였다. 또한, 입력 피쳐인 기상요인의 개별 예측 기여도 분석과 풍력 발전단지 에너지 생산량 예측 모델의 비교 분석을 통해 정확도를 평가하였다.

5장 “결론”에서는 본 연구의 핵심 결과 요약, 최종 결과물의 활용 가능성 및 향후 연구에 관해 기술하였다.

## II. 풍력 발전단지 환경 조건과 기상자료 수집

### 2.1 측정사이트와 관측장비 구성

본 연구는 대한민국 제주도 동북·북촌 풍력발전단지(Dongbok-Bukchon Wind Farm, DBWF)에서 수행되었다(Fig. 2.1a). 2015년 8월부터 현재까지 운영되는 D BWF는 한라산(높이 1,950m or 6,398ft)을 중심으로 북동쪽에 자리 잡고 있고, 해안에서 내륙 방향으로 약 1.5km 거리에 있다(Fig. 2.1b). 지형학적으로 제주도는 약 360여 개의 기생화산이 분포하는 전형적인 화산섬의 특징을 보인다[62]. 섬은 타원형으로 동서 방향으로 약 73km, 남북방향으로 약 41km 길이를 보인다. 한라산을 중심으로 동서 사면은 3~5°의 완만한 지형 기울기를 보이고, 남북 사면은 5~10°의 급격한 지형 기울기를 보인다.

제주도는 쾨펜의 기후 분류체계에 따라 아열대 습윤기후에 속한다. 여름철에는 아열대 고기압의 영향으로 국지성 호우가 빈번하고, 겨울철에는 대륙성 시베리아 고기압의 영향으로 시원하고 건조한 공기가 우세하다. 즉, 제주도는 대륙성 기후와 해양성 기후가 나타나는 접경지대에 놓여있다. 섬 전체의 연평균 기온은 15.6°C이고 열대야의 출현 빈도가 높은 지역이다. 열대야는 야간의 최저기온이 25°C 이상인 날로 고온 다습한 무더위가 밤에도 그대로 유지되는 현상을 의미한다. 제주도는 연평균 한 달 이상의 열대야를 보이고, 관측 기간 중 열대야 발생일 수는 39일로 나타났다. 또한, 여름철에는 태풍이 빈번하게 내습한다. 연평균 3.1회의 태풍이 영향을 미치며, 관측 기간 중 3회의 태풍이 발생하였다.

DBWF에는 정격출력 2MW인 풍력터빈 15기가 설치되어있다(Fig. 2.1c). 풍력터빈 사이의 이격 거리는 270~970m로 3D~11D(1D=86m)의 간격을 보인다. 발전단지 내에 설치된 80m 높이의 기상탑은 15호기 풍력터빈 북쪽 약 245m 거리에 위치한다. 풍력 발전단지를 포함한 주변 지역의 지표 상태는 나무, 수풀 및 농경지로 이루어져 있고, 단지 내에 분포하는 나무의 높이는 대략 2~5m이다. 사이트를 중심으로 해안가가 위치한 북쪽에서 내륙인 남쪽으로 해발고도는 점진적으로 증가한다.

사이트의 주 풍향은 북서풍으로 전체 풍향의 42.4%(300~330°)를 차지한다. 이

외의 서쪽과 동쪽의 풍향은 각각 15.1%(270°)와 24.8%(60~120°)를 차지한다(Fig. 2.1d). 기상탑을 기준으로 북풍 계열은 Freestream 섹터에 해당하고, 남풍 계열은 풍력터빈의 후류 영향을 받은 downstream 섹터에 해당한다.

DBWF의 지형 복잡도를 분석하기 위해 수치지도를 이용하여 Ruggedness Index(RIX)를 계산하였다. RIX는 타겟 사이트 내에서 특정 임계경사도 이상을 지닌 가파른 지형 표면의 비율로 정의된다[63]. DBWF의 기상탑을 중심으로 계산된 RIX(radius, 1.5km; sectors, 12; subsectors, 6; threshold, 0.3)는 0.79%로 나타났다. 이는 복잡 지형에서 나타나는 풍속의 가속(언덕 효과) 또는 유동 왜곡(탈착 흐름, 재순환 영역)과 같은 현상이 거의 발생하지 않는 지역으로 평탄 지형임을 의미한다.

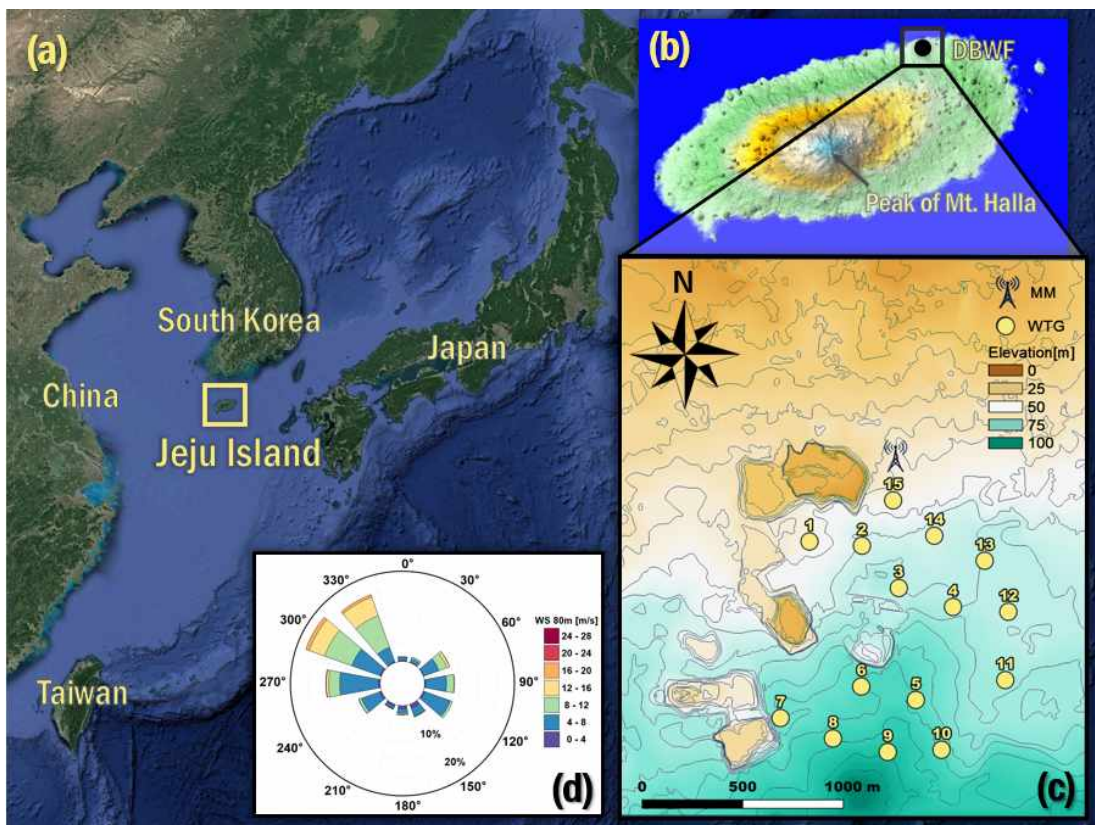


Fig. 2.1 Information on study site: (a) the geographic location of the site, (b) the location of the DBWF where the measurement campaign was conducted, (c) the layout of 15 wind turbines (Rated power 2MW), and (d) the wind rose of the study site. MM: meteorological mast, WTG: wind turbine generator.



Fig. 2.2는 DBWF에 설치된 80m 높이의 기상탑 전경이고, 기상탑에 장착된 바람 센서의 종류, 측정항목, 측정범위 및 기타 정보는 Table 2.1에 나타내었다. 컵형 풍속계와 풍향계의 설치지점은 80m와 40m 높이이고, 3차원 풍향·풍속계는 75m와 50m 높이이다. 3차원 풍향·풍속계는 수평( $u$  및  $v$ ) 및 수직( $w$ ) 속도 성분의 평균 흐름과 변동성분( $u'$ ,  $v'$  및  $w'$ )을 측정하며[64], 일반적으로 미기상학과 응용 기상학 연구에 자주 사용된다[65]. 이 바람 센서는 10Hz의 높은 측정 속도로 원시자료를 수집하기 때문에, 빠른 응답 특성을 갖추고 있어 난류 구조의 체계적인 정보를 수집할 수 있다.



Fig. 2.2 A view of the 80m tubular-type meteorological mast installed at the Dongbok-Bukchon wind farm in Jeju Island

이 수집된 자료를 바탕으로 대기안정도, TKE 및  $\varepsilon$ 의 10분 평균값을 계산하였다. 이때 자료의 정확한 측정을 위해, 관측장비의 빠른 응답속도가 유지되어야 한다. 따라서, 3차원 풍향·풍속계의 성능을 유지하기 위해 약 1년의 측정 기간 동안 설치업체를 통해 6회의 유지 보수와 현장 보정을 수행하였다.

Table. 2.1 Types and specifications of sensors installed on the meteorological mast for collection of weather data

Instrument	Parameters	Measurement range	Accuracy	Height [m]	
Cup anemometer: Thies First Class Advanced	Wind speed	0.3-5m/s	1 % of meas. value	80, 78.5, 40	
Wind vane: Thies Wind Vane First Class	Wind direction	0-360°	0.25 % of meas. value (1°)	78.5, 40	
3D sonic anemometer: CSAT3A*	Turbulence dissipation rate, Atmospheric stability	WS	U <sub>x</sub> (±30m/s) U <sub>y</sub> (±30m/s) U <sub>z</sub> (±30m/s)	U <sub>x</sub> (±8cm/s) U <sub>y</sub> (±8cm/s) U <sub>z</sub> (±8cm/s)	75, 50
		WD	0-360°	± 0.7°	
		T	-50 to 60 °C	0.025 °C	
Thermo-hydrometer: HygroClip2	Relative humidity, Temperature	0-100 % RH -100 to 200 °C	± 0.8 % RH ± 0.1 K at 10-30 °C	78.5	
Barometric pressure sensor: P-GE 6/11 economy	Pressure	600-1,100 hPa	0.1 %	78.5	

\*Sampling rate of 10 Hz. WS: wind speed; WD: wind direction; T: temperature; and RH: relative humidity.

DBWF에 설치된 풍력터빈은 정격용량이 2MW인 한진의 HJWT2000 모델이다. 해당 모델의 허브높이와 로터 직경은 각 80m와 86m이고, 블레이드 길이와 회전 면적(Swept area)은 각 42.2m와 5,809m<sup>2</sup>이다. 풍력터빈은 기어 시스템과 독립 피치 제어가 적용되어있고, 시동풍속은 3.5m/s, 정격풍속은 12m/s 및 종단풍속은 25m/s이다. DBWF에 설치된 총 15대 풍력터빈의 감시 제어 및 자료 취득(Supervisory Control And Data Acquisition, SCADA) 시스템에서 수집된 출력자료를 이용하여 분석을 수행하였다. SCADA의 출력자료와 기상탑의 바람 자료는 동시간대 10분 평균 자료를 사용하였다.

## 2.2 기상요인과 유효자료

### 2.2.1 기상요인 종류와 레짐 분류

국제전기표준위원회(IEC61400-1)에서는 환경 조건을 풍력터빈의 거동에 영향을 끼치는 환경 특성으로 다음과 같이 정의하고 있다.

“3.16 Environmental conditions characteristics of the environment (wind, altitude, temperature, humidity, etc) which may affect the wind turbine behavior” [66].

본 연구에서 다루는 환경 조건은 총 10가지(풍속, 풍향, 풍속전단지수, 기압, 기온, 상대습도, 대기안정도, 난류운동에너지, 난류 소산율, 난류강도)이며, 이 조건들은 풍력터빈에 영향을 미치는 기상요인이다. 이 중에서 1차적으로 측정되는 기상요인들은 풍속, 풍향, 기압, 기온 상대습도이고, 이를 기초로 하여 2차적으로 계산되는 기상요인들은 대기안정도, 난류운동에너지, 난류강도, 난류 소산율이다. 2차적으로 계산되는 매개변수의 상세한 설명은 다음과 같다.

#### 1) 풍속전단지수(Wind shear exponent, WSE, $\alpha$ )

일반적으로 대기 경계층 내에서의 풍속 연직 분포는 지수법칙이나 로그 법칙을 이용하여 근사화 할 수 있다. 본 연구에서는 지수법칙을 이용하여 무차원 WSE를 계산하였다. 수식은 아래와 같다[14].

$$\alpha = \frac{\ln(v_2/v_1)}{\ln(z_2/z_1)} \quad (1)$$

여기서,  $z_1$ 과  $z_2$ 는 지표면에서부터 수직으로 2개 지점의 높이  $v_1$ ,  $v_2$ 는 각 높이에서의 풍속을 나타낸다. WSE는 기상탑의 40m와 80m 높이의 풍속자료를 이용하여 계산하였다. 이를 이용하여 대기안정도 변화에 따른 WSE의 산포 특성을 분석하였다.



## 2) 난류강도(Turbulence intensity, TI)

난류성분이 풍력터빈의 출력에 미치는 영향을 확인하고자 TI를 이용하여 분석하였다. TI는 바람의 산란 지표로서 10분 평균풍속과 이에 대한 표준편차의 비로 정의된다. TI는 풍력터빈의 설계 요구사항인 IEC 61400-1에서 제안한 하단의 수식을 사용하였다[21].

$$TI = \frac{\sigma}{\bar{v}} \quad (2)$$

여기서,  $\sigma$ 는 풍속의 표준편차,  $\bar{v}$ 는 풍력터빈 허브높이의 10분 평균풍속을 나타낸다. 본 연구에서는 기상탑의 80m 컵형 풍속계의 자료를 이용하여 TI를 산출하였다. 이를 이용하여 대기안정도 변화에 따른 TI의 산포 특성을 분석하였다.

## 3) 대기안정도

일반적으로 풍력공학에서 자주 사용하는 대기안정도 함수는 오버콕 길이와 리처드슨 수(Richardson number, Ri)이다[18,64,67,68]. 이 중에서 Ri는 두 군데 연직 지점의 풍속과 온도차이를 이용해 대류 난류를 기계적 난류로 전환시키는 비율을 측정한 동적 안정도 매개변수이다[69].

3차원 풍향풍속계가 설치된 지점은 50m와 75m로, 풍력터빈의 회전 면적 내에 위치한다. 리처드슨 수(Richardson number, Ri)를 사용할 경우, 이 회전 면적에 노출되는 풍속 차이와 온도 차이를 고려할 수 있다. 이는 풍력터빈 로터가 겪는 환경 조건을 통합하는 것이며, 직접적인 반영이 이루어지는 것이기에 단 하나의 특정 높이에서 측정된 데이터를 사용하는 obukhov 길이보다 좋은 선택이 될 수 있다[70]. 따라서, 본 연구에서는 2기의 3차원 풍향·풍속계에서 수집된 자료를 이용하여 무차원수인 총체 Ri를 계산하였다. 수식은 아래와 같다.

$$Ri = \frac{g \Delta T \Delta z}{T \Delta U^2} \quad (3)$$

여기서,  $g$ 는 중력가속도로  $9.81 \text{ m/s}^2$ ,  $\Delta T$ 는  $\Delta z$ 에서의 온도변화,  $\Delta z$ 는 두 군데 측정지점의 연직 높이 변화,  $\Delta U$ 는  $\Delta z$ 에서의 수평 풍속변화,  $\bar{T}$ 는  $\Delta z$ 에서의 평균 온도를 나타낸다.

#### 4) 난류운동에너지(Turbulent kinetic energy, TKE)

일반적으로 풍력공학에서 사용하는 난류강도는 전체적인 난류 수준의 통계적 변수로서, 대류 난류와 기계적 난류를 정량적으로 구분하지 못한다. 따라서 난류 성분이 풍력터빈의 출력에 미치는 영향을 확인하기 위해, 3축 속도 성분이 반영된 TKE를 산출하였다. 수식은 아래와 같다.

$$TKE = \frac{1}{2}(\overline{u'^2} + \overline{v'^2} + \overline{w'^2}) \quad (4)$$

여기서,  $u'$ ,  $v'$  및  $w'$ 은 수평( $u$ ,  $v$ )과 수직( $w$ ) 속도 성분의 변동성분을 나타낸다.

#### 5) 난류 소산율(Turbulent dissipation rate, TDR, $\epsilon$ )

콜모고로프는 매우 높은 레이놀즈수에서 난류 흐름 내의 소규모 운동은 통계적으로 등방성이라 가정하였다[71]. 콜모고로프는 이러한 특성을 설명하기 위해 국지 상사 이론을 제안하였다. 이 이론은 평균 흐름 또는 가장 활동적인 맴들의 특성 레이놀즈수가 충분히 클 때, 에너지가 소규모 운동으로 소멸하기 전에 여러 단계에 걸쳐 일어난다는 것이다. 또한, 큰 에디의 연속적인 붕괴과정을 통해 형성된 작은 에디는 균질하고 등방성을 나타낸다는 것이다 [69]. 여기서 난류의 운동에너지는 점성력에 의해 궁극적으로 열적 내부 에너지로 변환 소멸하며, 이 일련의 소멸 과정을 에너지 폭포(Energy cascade)라 부른다(Fig. 2.3 참조). 난류 흐름 내에서 이 과정이 나타날 때, 점점 더 작은 스케일의 와류로 분해되는 비율이 바로  $\epsilon$ 이다[71].  $\epsilon$ 은 단위 질량 당 운동에너지(단위는  $\text{m}^2/\text{s}^3$ )로 표현되며, 일반적으로  $\epsilon$ 을 산출하기 위해 3D 음파 풍향·풍속계를 사용한다. 이 장비를 이용하여  $\epsilon$ 을 계산하는 방법은 크게 2가지이다. 관성 아영역(Inertial subrange) 에너

지 스펙트럼 기법과 2차 구조 함수기법이다.




Fig. 2.3 Turbulent energy spectrum based on the Kolmogorov hypothesis.

ABL을 연구하는 분야에서는 주로  $\epsilon$ 을 파수의 함수로 표현하여 스펙트럴 에너지를 나타낸다[22,72]. 이때 스펙트럴 에너지의 기울기는 콜모고로프 관성 아영역의 이론적 기울기(-5/3)에 맞추어 계산한다[73]. 관성 아영역 내의 주파수에서 속도 성분의 파워 스펙트럼 밀도(power spectral density)는 아래 수식으로 가정한다.

$$S_u(f) = \alpha \left( \frac{\epsilon \bar{U}}{2\pi} \right)^{2/3} f^{-5/3} \quad (5)$$

방정식 2를 이용하여  $\epsilon$ 을 계산하는 수식은 아래와 같다.

$$\epsilon = \frac{2\pi}{\bar{U}} \left[ \frac{S_u(f) f^{5/3}}{\alpha} \right]^{3/2} \quad (6)$$

여기서,  $S_u(f)$ 는 파워 스펙트럼 밀도,  $f$ 는 주파수 및  $\alpha$ 는 콜모고로프 상수이다. 본 연구에서 콜모고로프 상수는 0.52로 가정하여 파워 스펙트럼을 분석하였다(Fi

g. 3.4참조) [74,75]. 콜모고로프 유사성 가설[76]에 기초하면, 등방성 난류를 보이는 관성 아영역 내에서는 속도 증분과 에너지 소실이 관계가 있다. 속도 증분은 속도의 2차 구조함수( $D_u$ )로 표현되며, 수식은 아래와 같다.

$$D_u(r) \equiv \langle [U(x+r) - U(x)]^2 \rangle = \frac{1}{\alpha} \epsilon^{2/3} r^{2/3} \quad (7)$$

여기서,  $D_u(r)$ 은 관성 범위 내에서 유동 방향으로 공간 분리  $r$ 에 유효한 SSF (Second-order Structure Function)이다.  $U$ 는 수평속도,  $\langle \cdot \rangle$ 은 앙상블 평균을 나타낸다. 콜모고로프의 가설은 공간 증분 측면에서는 공식화되었으나, 시간 속도 증분 측면에서  $\epsilon$ 을 표현할 때는 테일러의 동결 난류 가설[77]을 적용하는 것이 일반적이다. 테일러의 가설은 난류의 변화하지 않는 패턴 또는 동결 패턴을 가정하여 평균 흐름 방향 내에서 난류 변수의 공간 변동과 고정 점에서의 시간 변동 사이의 직접적인 대응을 의미한다. 이에 따라  $\epsilon$ 은 아래와 같은 수식으로 나타낸다.

$$\epsilon = \frac{1}{U\tau} [aD_u(\tau)]^{3/2} \quad (8)$$

여기서,  $D_u(\tau)$ 은 시간 증분  $\tau$ 에 대한 수평속도  $U$ 를 이용하여 산출된 SSF이다. SSF 기법의 이산화에는 미소 지연 현상이 거의 없고[78], 스펙트럴 에너지 기법에 비해  $\epsilon$  추정과정에서 낮은 오류를 보인다[79]. 따라서 본 연구에서는 SSF 기법을 이용하여  $\epsilon$ 을 산출하였다.

$\epsilon$ 은 관성 아영역 범위 내에서 계산되어야 하며, 이때 시간 증분 값은 0.05~2s 이고, 주파수 범위로는 0.5~20Hz이다[70]. 본 연구에 사용된 3D 풍향·풍속계는 10Hz(0.1s)의 샘플링 비율(sampling rate)을 보이기 때문에 이 장비로 수집된 자료를 이용하여, 스펙트럴 에너지를 분석하였다(Fig. 2.4). 3개 속도 성분의 스펙트럴 에너지는 낮은 파수에서 강한 에너지를 보이고, 파수가 증가함에 따라 에너지가 감소하는 경향을 보인다. 이때 10Hz의 측정 속도는 이론적 기울기(-5/3)와 일

치한다. 즉, 관성 아영역 범위 내에서 큰 스케일과 작은 스케일의 분리가 충분하다는 것을 의미한다.  $\varepsilon$ 과 풍력터빈 출력 자료와의 동 시간대 분석을 위해, SSF의 앙상블 평균은 10분으로 계산하였다[70]. 일반적으로 풍력터빈은 IEC-61400에 따라 10분 평균 데이터 세트를 활용하기 때문이다[21].

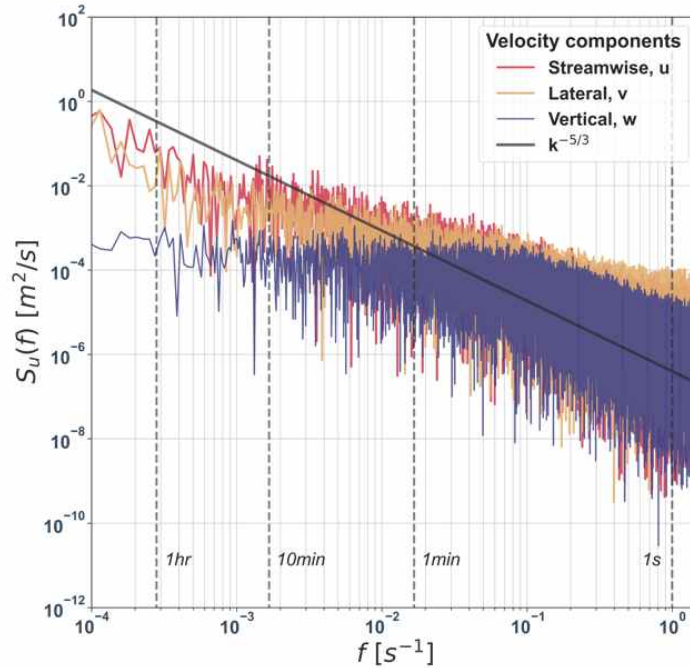


Fig. 2.4 Energy spectrum of the turbulent-velocity component. Data from the 3D sonic anemometer installed at 75 m on the meteorological tower were used for the period from 12:00 AM to 1:30 PM on February 5, 2017. The black solid line represents the theoretical slope (-5/3) of Kolmogorov's inertial subrange in the frequency region.

Table 2.2는 기상요인의 레짐 분류를 위한 임계값(thresholds)을 나타낸다. 임계값 정의를 위해 참고문헌[16,18,19,68]을 검토한 결과, 임계값은 완전히 동일하지 않지만 유사한 수준을 나타낸다. 임계값 설정 시 고려한 특성은 해당 사이트의 토지 피복, 관측 높이 및 기후 특성 등이다. 또한, 레짐에 따른 데이터의 정보를 보다 잘 표현 하기 위해 약간의 수정을 거친 임계값을 적용하였다. 본 연구에서도 참고문헌을 기준으로 상기에 언급한 사이트의 특성을 반영하여, 유사한 수준의 레짐 분류 기준을 설정하였다. DBWF는 나무가 빼곡한 숲에 위치하기 때문에 타 사이트에 비해 높은 수준의 WSE와 TKE를 보인다. 이 점을 고려하여 해당 기상요인의 임계값을 설정하였다.

Table. 2.2 Definition of thresholds for classification of stability regimes

Stability regimes	Parameters			
	Bulk Richardson number (label)	Turbulence intensity	Wind shear exponent	Turbulent kinetic energy
Unstable condition	Strongly unstable(u3): $Ri < -2$			
	Moderately Unstable(u2): $-2 \leq Ri < -0.5$	High: $0.15 \leq TI$	Weak: $\alpha < 0.26$	High: $2.35 < TKE$
	Slightly unstable(u1): $-0.5 \leq Ri < -0.17$			
Neutral condition	Neutral(n): $-0.17 \leq Ri < 0.02$	Moderate: $0.10 \leq TI < 0.15$	Moderate: $0.26 \leq \alpha < 0.36$	Moderate: $1.00 \leq \alpha < 2.35$
Stable condition	Stable(s): $0.02 \leq Ri$	Low: $TI < 0.10$	Strong: $0.36 \leq \alpha$	Low: $TKE < 1.00$

대기안정도인 Ri를 크게 불안정 · 중립 · 안정 레짐으로 분류하였다. 분류된 3가지 레짐에 따라 DBWF의 발생빈도를 분석한 결과, DBWF의 대기상태는 불안정 조건이 우세하였다(Fig. 2.5 참조). DBWF는 불안정 레짐의 출현 빈도가 높기 때문에 보다 세부적인 분석을 위해 불안정 레짐을 다시 3가지 범주로 분류하였다. 세분화된 레짐은 강한 불안정(u3), 중간 불안정(u2) 및 약한 불안정(u1)으로 최종적으로 5개 레짐으로 분류하였다. 레짐에 따른 발생비율은 강한 불안정, 중간 불안정, 약한 불안정, 중립 및 안정 순서로 24.6, 35.2, 26.8, 8.3 및 5.2%을 보이며, 자료 필터링을 적용한 후의 발생비율은 Fig. 2.5와 같다

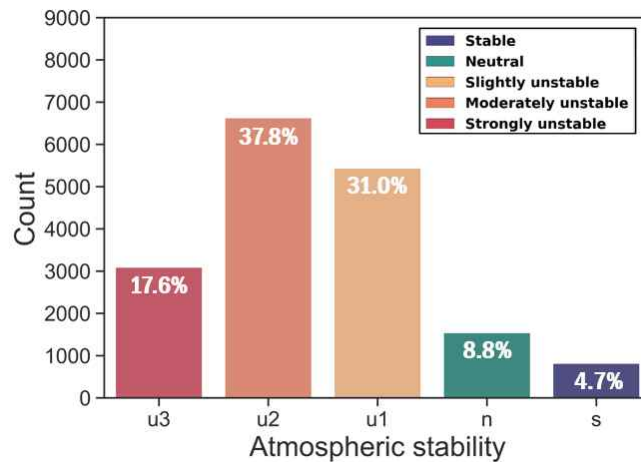


Fig. 2.5 Frequency ratio according to Ri. The Ri was calculated using the temperature and wind speed data collected from 3D sonic anemometers with filtering. u3 - strongly unstable, u2 - moderately unstable, u1 - slightly unstable, n - neutral, and s - stable.

대기안정도는 사이트에 따라 편향된 경향을 보이기도 한다. 브라질 연안 지역에서 수행된 [80]의 연구에서는 불안정상태가, 미국 내륙 지역에서 수행된 [70]의 연구에서는 안정상태가 우세한 것으로 보고된다. 추가로 [81]의 연구는 제주도 남서쪽 약 150km 거리의 완전한 해상 환경에 있는 종합과학기지에서 수행되었다. 관측된 대기안정도는 안정, 준 불안정(semi-unstable) 및 불안정 순서로 1.12, 28.76, 70.11%의 출현 빈도율을 보인다. 이를 고려하면, DBWF가 위치한 제주도는 종관적 기후 특성에 의해 해상 환경과 근접한 사이트일수록 불안정 대기상태의 출현 빈도가 높을 것으로 추정된다. 이외에도 TI, WSE 및 TKE의 레짐에 따른 자료의 분포 비율은 Table 2.3과 같다.

Table. 2.3 Number of valid data and frequency ratio with regime of meteorological factors

Stability class	Number of valid data (#) and frequency ratio [%]		
	Turbulence intensity	Wind shear exponent	Turbulent kinetic energy
Unstable condition	#6333, 36.1%	#3132, 17.8%	#5731, 32.7%
Neutral condition	#7947, 45.3%	#4797, 27.3%	#6152, 35.13%
Stable condition	#3268, 18.6%	#9619, 54.8%	#5665, 32.3%

### 2.2.2 자료 품질 관리

측정 캠페인 동안 수집된 자료의 기간은 약 1년(2016.03~2017.02)이다. 관측 장비별 취득된 자료의 가용률을 살펴보면, 3차원 풍향·풍속계, 기상탑에 장착된 바람 센서(컵형 풍속계, 풍향계, 온·습도계 및 기압계) 및 풍력터빈에 따라 각각 96.4%, 99.9% 및 97.7%이다.

측정자료를 분석하기 전에 자료의 품질관리를 수행하였다. 우선, 기상탑에서 취득된 기상 자료에 대해 필터링을 적용하였다. 3D 풍향·풍속계의 수평속도 성분(u와 v)과 수직 속도 성분(w)에 대해 각각  $\pm 30\text{m/s}$ 와  $\pm 5\text{m/s}$  이내의 자료를 사용하였다. 이 관측 장비의 측정 속도는 10Hz이기 때문에, 순간적인 전기 신호로 스파크가 발생할 가능성이 있다. 스파크가 발생하면 관측 허용범위를 벗어난 비정상적인 값이 측정된다. 따라서, 10분 동안의 표준편차가 평균값에 10배 이상인 관측 자료는 폐기하였다. 이외에 컵형 풍속계와 온도계는 각각 3~25m/s와 -10



~40℃ 이내의 자료만 사용하였다.

다음, 풍향 필터링과 SCADA의 풍력터빈 출력자료에 필터링을 적용하였다. 이때 본 연구의 목적에 맞게 필터링 조건을 3개로 분류한 후, 이를 만족한 유효자료를 이용하여 분석을 수행하였다. 그 기준은 아래와 같다.

### 1) 단일 풍력터빈 자료: 15번 풍력터빈

이 자료는 기상요인의 레짐에 따른 단일 풍력터빈의 AEP 차이 분석을 목적으로 한다. 이를 위해 기상탑의 풍속과 풍향 변화에 따른 TI 분석을 바탕으로 풍향 필터링을 수행하였다(Fig. 2.6). 일반적으로 TI는 저 풍속에서는 강하지만, 풍속이 점점 증가하면서 그 강도가 약해지는 경향을 보인다. 이와 같은 특성에도 불구하고, 180° 섹터 부근의 바람은 고풍속에서도 여전히 높은 TI를 보인다. 이는 기상탑 남쪽에 설치된 열다섯 기 풍력터빈의 영향으로 판단된다(Fig. 2.1c, 풍력터빈 배치 참조).

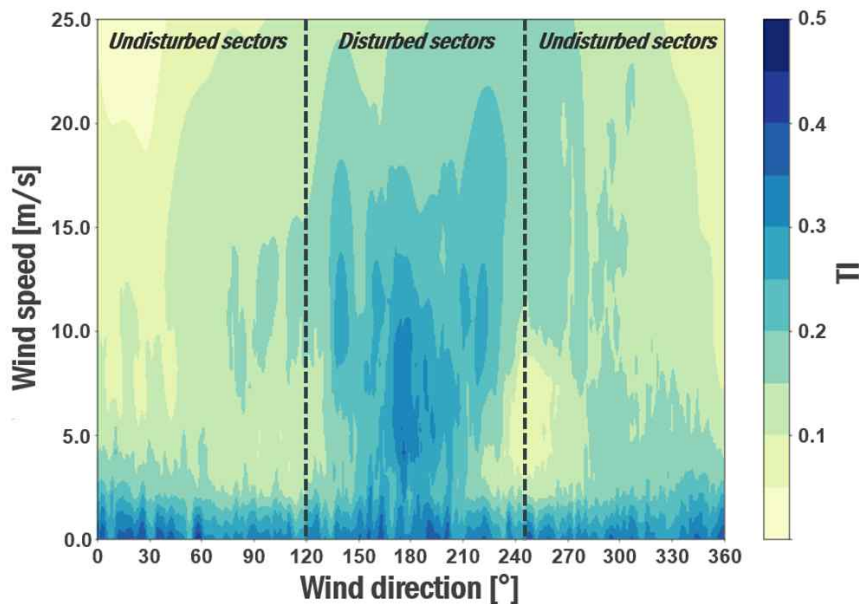


Fig. 2.6 Turbulence intensity (TI) distribution according to the changes in wind direction and wind speed. Data was collected from the 78.5m high wind vanes and 80m high cup anemometers installed on the meteorological mast. The dotted lines differentiate the disturbed and undisturbed sectors.



다수의 풍력터빈에 의해 풍속이 저감된 후류 영역의 바람장은 주변부 바람장과의 혼합 작용을 통해 풍속을 회복한다. 이 현상으로 인해 풍속이 증가에도 불구하고, 고 TI가 지속되는 것으로 풀이된다. 따라서 기상탑을 기준으로 풍력터빈 블레이드의 회전 거동으로 인해 교란된 120~246° 섹터를 제외하고, 그 외에 비교란 섹터의 측정자료를 활용하였다. 이때 배제 각 산정은 IEC 61400-12-1에 따라 계산하였다[21].

풍력터빈의 출력자료에 대한 필터링도 수행하였다. 풍력터빈의 운전영역 풍속 구간에서 출력이 비정상적으로 낮게 나오거나 10분 평균 출력의 표준편차가 0kW인 데이터는 폐기하였다. 이를 통해 풍력터빈이 정상 운전상태인 자료만을 사용하였다. 관측 기간 동안 수집된 약 오만 개의 10분 평균자료에 대해 상기에 언급된 필터링을 이용하였고, 최종적으로 17,548개의 자료를 확보하였다. 해당 자료는 4.1.1절과 4.1.2절에 활용되었다.

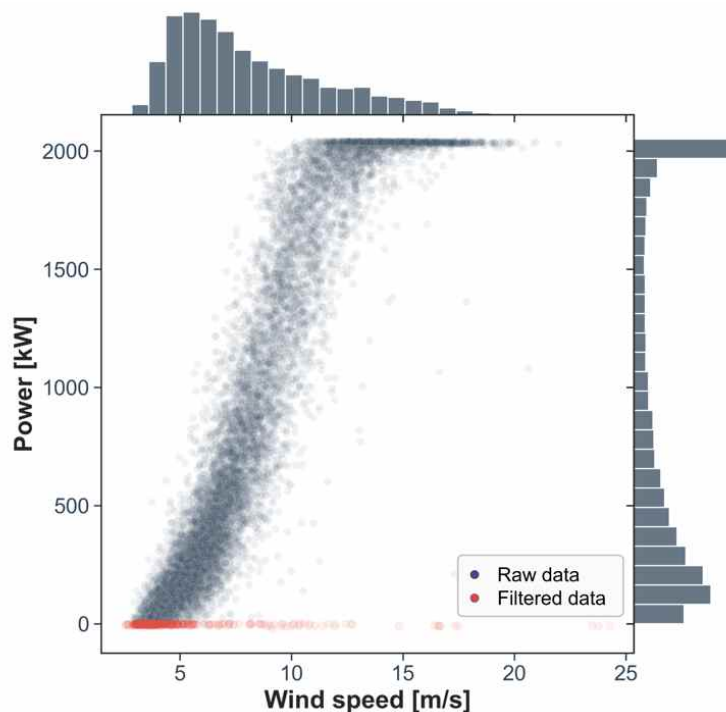


Fig. 2.7 Valid power data for WTG No. 15. Identical filtering conditions were applied to all 15 WTGs in the DBWF; only valid data for the same period satisfying the necessary conditions were used for analyses. The number of valid 10-min averaged power data points was 5,158 for a single WTG and 77,370 for all the WTGs.

## 2) 풍력 발전단지 자료: 15기 풍력터빈

이 자료는 대기안정도에 따른 풍력 발전단지의 AEP 차이 분석을 목적으로 한다. 이를 위해 우선 DBWF의 유효 방위각인 246~120°의 관측 자료만을 이용하여 분석을 수행하였다. 다음, 풍력 발전단지에 설치된 전체 15기 풍력터빈의 출력자료에 대해 필터링을 수행하였다. 풍력터빈이 운전풍속 구간임에도 불구하고 출력이 마이너스 값, 비정상적으로 낮은 값 및 10분 평균 표준편차가 0kW인 값을 폐기하였다(Fig. 2.7 참조). 최종적으로 이 조건을 만족한 기상탑과 SCADA의 유효자료 수는 각각 12,247개와 5,158개이다. SCADA 자료의 경우, 15기 풍력터빈 모두 동 시간대 정상 운전상태의 자료임을 의미한다. 해당 자료는 4.1.3절에 활용되었다.

## 3) 풍력 발전단지 자료: 기계학습 모델 구축을 위한 15기 풍력터빈 자료

이 자료는 ML 알고리즘을 이용한 풍력 발전단지 에너지 생산량 예측과정에서 기상요인의 예측 기여도 분석을 목적으로 한다. SCADA의 출력자료 필터링은 상기의 “2) 풍력 발전단지 자료: 15기 풍력터빈”과 동일한 기준을 적용하였고, 추가로 다변량 대체(Multivariate imputation) 방법을 수행하였다. 이 방법은 한 기의 풍력터빈 출력값이 누락되었을 경우 나머지 풍력터빈 출력값의 함수로 모델링한 후에 모델을 이용한 추정치를 산출하여 누락된 값을 대체하는 방식이다. 풍력터빈 출력자료 손실을 최소화하여 기계학습을 진행하기 위해 이와 같은 방법을 사용하였다. 해당 기법은 파이썬의 Scikit-learn 라이브러리를 이용하여 수행하였다[82]. 이외에 풍향 필터링은 적용하지 않았으며, 최종적으로 11,688개의 유효자료를 확보하였다. 이 자료는 두 가지 시간해상도인 “10분 평균자료”와 “1일 평균자료”로 구성하였으며, 4.2절에 활용되었다.

## 4) 풍력 발전단지 자료: 기계학습 모델의 예측 정확도 평가 자료

이 자료는 풍력 발전단지 에너지 생산량 예측 모델의 정확도 평가를 목적으로 한다. 평가를 위해 모델 구축과정에서 한 번도 노출되지 않은 자료인 2017년 04월~2017년 11월까지의 기상탑과 SCADA 자료를 활용하였다. 자료 품질관리를 거쳐 확보된 유효한 10분 평균자료와 1일 평균자료는 각각 8,821개와 180개이다.

이 자료는 3D 풍향·풍속계에서 취득되어 계산되는 대기안정도와 각종 난류 특성값들이 존재하지 않는다. 따라서 별도로 하위 예측 모델을 구축하여 이 매개 변수들을 예측하였다. 최종적으로 이 하위 예측 모델의 활용 전·후 풍력 발전단지 에너지 생산량(10분 평균 출력과 1일 발전량) 예측 모델의 정확도를 비교 분석하였다. 이 자료는 4.3절에 활용되었다.

### III. 모델 구축과 성능 평가 방법

#### 3.1 연간발전량과 정규화된 출력 계산

단일 풍력터빈 분석의 경우, DBWF에 위치한 15호기 풍력터빈을 선정하였다(Fig. 2.1c 참조). 15호기 터빈은 기상탑에 가장 가깝고, 주 풍향인 북서풍의 자유 유동 영역의 자료를 가장 많이 수집할 수 있기 때문이다. 이 점은 기타 풍력터빈에 비해 기상요인에 따른 출력 특성 분석을 보다 엄밀히 수행할 수 있게 해준다. 출력 분석을 위한 표준 대기압 상태로의 보정과 이를 이용한 풍속 정규화는 IEC 61400-12-1에 따라 수행하였다[21].

일반적으로 풍력터빈 출력 특성을 연구할 때 사용되는 풍속자료는 크게 4가지 방식으로 수집된다. 기상탑 풍속계, 나셀 풍속계, 지상 기반 원격탐사 장비인 소다와 라이다 및 나셀 라이다를 활용하는 방식이다[16,18,19,83,84]. 본 연구에서는 기상탑 허브높이에 장착된 컵형 풍속계와 나셀 풍속계의 자료를 활용할 수 있다.

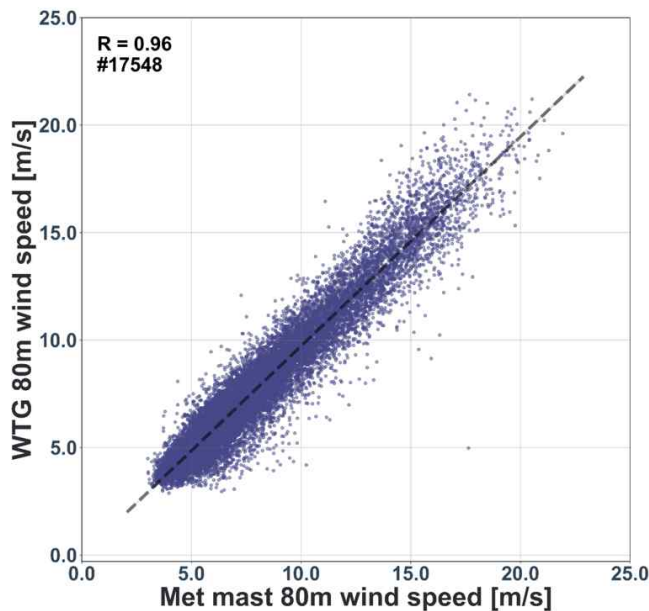


Fig. 3.1 Comparison of wind speed data measured by 80m high meteorological mast (Cup anemometer) and 80m high wind turbine (nacelle anemometer for 15th wind turbine generator). When the wind turbine is in normal operation, 10 min-averaged data of wind speeds between 3 and 25 m/s, and wind directions 246-120 ° were used.

두 계측기에서 수집된 풍속자료의 상관계수 분석 결과, 0.96으로 높은 수준을 보였다(Fig. 3.1). 초기 분석 단계에서 두개의 풍속자료를 이용하여 레짐에 따른 출력곡선 분석을 비교하였다. 레짐에 따른 출력 곡선의 차이와 출력 증감 패턴이 나셀 풍속계 자료를 활용하였을 때보다 뚜렷하게 나타났다. 따라서 단일 풍력터빈의 출력 분석 시, 나셀 풍속계 자료를 활용하였다. 또한, 출력 곡선 분석에서 사용된 오차 막대(error bars)는 중앙 절대 편차(MAD, median absolute deviation)를 이용하여 계산하였다. 일반적으로 사용되는 표준편차를 적용할 경우, 단 하나의 관측자료에 의해 그 값이 임의로 심하게 증가하는 이상치 효과(outlier effects)에 영향을 받을 가능성이 크다[85]. 따라서, 이상치 효과를 최소화하면서 표준편차와 유사한 MAD를 이용하여 분석을 수행하였다.

### 1) 연간발전량 계산

AEP는 풍력터빈의 측정자료로 산출된 출력 곡선과 레일리 분포의 풍속 확률밀도를 이용하여 계산하였다. 출력 곡선은 시동풍속에서 정격풍속까지 기상요인별로 산정하였고, 정격풍속인 12m/s 이상의 풍속부터는 정격출력인 2,000kW로 가정하였다. AEP 산정 시, 레일리 분포의 연 평균 풍속은 4~12m/s를 사용하였다. AEP 계산 수식은 아래와 같다[21].

$$AEP = N_h \sum_{i=1}^N [F(V_i) - F(V_{i-1})] \left( \frac{P_{i-1} + P_i}{2} \right) \quad (9)$$

여기서,  $N_h$ 는 연간 시간으로 8,760시간,  $N$ 은 빈의 수,  $V_i$ 는 빈  $i$ 에서의 표준화된 평균 풍속이고  $P_i$ 는 그에 따른 출력이다. 풍속에 대한 레일리 누적 확률 분포 함수의 수식은 아래와 같다.

$$F(V) = 1 - \exp\left(-\frac{\pi}{4} \left(\frac{V}{V_{ave}}\right)^2\right) \quad (10)$$

여기서,  $F(V)$ 는 풍속에 대한 레일리 누적 확률 분포 함수,  $V_{ave}$ 은 연 평균 풍

속,  $V$ 는 풍속이다.

## 2) 정규화된 출력 계산

정규화된 출력은 주 풍향 기준으로 자유 유동에 위치한 풍력터빈의 출력과 그 외 개별 풍력터빈의 출력비로 계산한다. 출력 분석 전, 표준 대기압 상태로의 보정과 풍속 정규화는 IEC61400-12-1에 따라 수행하였고[21], 정규화된 출력의 수식은 아래와 같다.

$$P_{nor}(i) = \frac{P_{wake,i}}{P_{free,i}} \times 100 \quad (11)$$

여기서,  $P_{nor}(i)$ 은 풍력터빈의 정규화된 출력이다.  $P_{free}$  [kW]는 자유 유동에 위치한 15번 풍력터빈의 출력을  $P_{wake}$  [kW]는 기타 개별 풍력터빈의 출력이다.  $i$ 는 동 시간대 10분 평균을 나타낸다. 정규화된 출력은 4.1.3절에서 활용되었다.

## 3.2 통계검정

기상요인의 분류된 레짐에 따라 정규화된 출력을 계산하였다. 이때 레짐에 따라 정규화된 출력의 차이가 발생하였고, 이 차이가 유의미한 차인지 판단하기 위해, 통계적 검정을 수행하였다.

### 1) 정규성 검정(Normality test)

콜모고로프 스미르노프 검정으로 정규화된 출력 데이터 세트의 정규성을 파악하였다. 데이터 세트는 5개 대기안정도 레짐과 15기 풍력터빈에 따라 75개로 구분되었고, 각 데이터 세트는 132~1,505개의 10분 평균값으로 구성되었다. K-S 검정은 자료의 가장 작은 값부터 가장 큰 값까지의 누적 상대빈도가 이론적 정규분포의 누적 상대빈도와 얼마나 다른지를 검정하는 방법이다[86]. 유의확률인  $P$ 값이 0.05보다 크면 정규분포를 가정하고, 이보다 작으면 정규분포를 가정하지 않는다[87,88]. 분석 결과, 75개 데이터 세트는 정규성을 보이지 않았다. 따라서

정규분포의 전제가 불필요한 비모수 검정 방법을 선택하였다.

## 2) 만-휘트니 U검증(Mann-Whitney test)

비모수 검정 방법인 Mann-Whitney U test (또는 Wilcoxon rank sum test라고도 불린다)를 이용하여 정규화된 출력의 차이를 검정하였다. 이 기법은 서로 다른 두 모집단의 차이에 대해 순위 합을 이용하여 분석하는 방법이다[50][89]. 통계적 검정은 대기의 약한 불안정 레짐을 기준으로 기타 레짐과의 정규화된 출력 차이에 대해 수행하였다. 유의확률인 P값이 0.05보다 크면 약한 불안정 레짐과 비교 레짐간의 정규화된 출력 차이는 없다고 보며, 이보다 작으면 통계적으로 차이가 있음을 의미한다. 기상요인의 레짐 변화에 따른 풍력터빈의 출력성능 차이를 제시하는 몇몇 연구에서 Mann-Whitney U test가 사용되었다[16,19].

## 3.3 모델링과 검증

일반적으로 통계적 모델링 기반 접근방식에서 주로 사용되는 입력 피처는 풍속, 풍향, 온도, 습도, 압력 및 풍속전단지수이다[39]. 이들 매개변수 외에 본 연구에 추가한 입력 피처는 대기안정도인 Ri, TKE,  $\epsilon$  및 TI이다.

Table. 3.1 Summary of classified input feature groups and meteorological factors.

Group number	Meteorological factors [unit], acronym	Height [m]
Group 1	Wind speed [m/s], WS	80
	Wind direction [°], WD	78.5
	Wind shear exponent [ ], WSE	80/40*
	Ambient pressure [kPa], Pamb	78.5
	Temperature [°C], T	78.5
	Relative humidity [%], RH	78.5
Group 2	Richardson number [ ], Ri	75/50**
	Turbulence kinetic energy [m <sup>2</sup> /s <sup>2</sup> ], TKE	75, 50
	Turbulence dissipation rate [m <sup>2</sup> /s <sup>3</sup> ], $\epsilon$ , eps	75, 50
	Turbulence intensity [ ], TI	80, 40

\*WSE was calculated using data from cup-type anemometers with heights of 80m and 40m.

\*\*Ri was calculated using data from 3D anemometers with heights of 75m and 50m.



Table 3.1은 분류된 기상요인 그룹과 기타 정보를 나타낸다. 그룹1은 기존 연구에서 자주 사용되는 6개의 기상요인으로 구성하였다. 그룹2는 그룹1 이외의 요인인 대기안정도와 난류 특성값들로써, 측정 높이에 따라 7개로 구성하였다. 기상요인들은 풍력터빈의 허브높이 부근과 풍력터빈 회전 면적의 하부높이에서 취득한 자료이다.

### 3.3.1 기계학습 알고리즘

본 연구에 사용된 ML 알고리즘은 support vector machine, SVM; random forest, RF; light gradient boosting model, LGBM; 및 artificial neural network, ANN으로 4가지이다.

SVM은 분류 또는 회귀분석에 사용 가능한 초평면 또는 초평면의 집합으로 구성된다. 최적의 초평면을 구하는 알고리즘의 시초는 선형 분류였으나, 이후 최대 마진 초평면 문제에 커널 트릭을 적용하면서 비선형 분류가 제안되었다[90,91]. 비선형 분류 알고리즘은 내적 연산이 비선형 커널 함수로 대체되면서 특성 공간의 최대 마진 문제를 해결할 수 있게 되었다.

RF는 앙상블 알고리즘의 일종으로 훈련 과정에서 구성된 다수의 결정 트리를 분류 또는 회귀분석 문제의 해결을 위해 활용된다. RF는 여러 개의 결정 트리 분류기가 전체 데이터에서 배깅 방식으로 각각의 데이터를 샘플링해 개별적으로 학습을 수행한 후, 모든 분류기의 보팅을 통해 최종적으로 예측을 결정하게 된다 [92,93].

LGBM은 학습에 걸리는 시간과 메모리 사용량이 적고, 예측 성능도 우수하여 부스팅 계열에서 가장 각광 받는 알고리즘이다. 기존에 사용된 대부분의 트리 기반 알고리즘은 트리의 깊이를 효과적으로 줄이기 위해 균등 트리 분할 방식을 사용한다. 반면에 LGBM은 리프 중심 트리 분할 방식을 사용한다. 이 방식은 최대 손실 값을 가지는 리프 노드를 지속적으로 분할하는 방식으로 학습을 반복할 수록 균형 트리 분할 방식보다 예측 오류 손실을 최소화할 수 있다[94].

ANN은 기본적으로 사람의 뇌에 있는 신경세포의 신호전달 과정을 모방하여 인공적으로 구성된 네트워크이다. 이는 입력과 출력층 사이에 한 개 이상의 완전 연결 은닉층을 추가하고 각 은닉층의 결과에 ReLU 함수, Sigmoid 함수 및 Tan

h 함수와 같은 활성화 함수를 적용한 것이다. 이를 통해 입력 자료값과 출력 자료값의 가중치가 반복적으로 조정되어 최종적으로 입력 자료와 출력 자료 사이의 관계가 학습되는 구조이다[95]. 상기의 4가지 ML 알고리즘은 파이썬의 사이킷런에서 지원하는 모듈인 Support Vector Regression, Random Forest Regressor, LGBM Regressor 및 Multi-layer Perceptron을 이용하였다.

### 3.3.2 하이퍼파라미터 최적화와 교차 검증

본 연구의 목적은 입력 피쳐인 기상요인에 따른 ML 알고리즘의 예측 정확도를 확인하고, 기상요인의 기여도를 평가하는 것이다. 따라서, 각 ML 기법의 성능

Table. 3.2 Optimized hyperparameter settings for each ML algorithm.

Learning algorithms	Hyperparameters	List	Hyperparameters optimized for each sampling time of the data	
			10-min average	Daily average
SVM	Gamma	[10, 1, 0.1, 0.01, 0.001]	1, 0.1	10
	C	[0.1, 1, 100, 1000]	1000	1000
	Kernel	[linear, rbf, sigmoid]	rbf	linear
RF	n_estimators	[100, 200, 300, 400]	200	100
	max_depth	[5, 10, 15, 20]	15, 20	5, 10
	max_features	[4, 6, 8, 12, 14]	4, 6	6
	min_samples_leaf	[4, 6, 8, 12]	4	4
	min_samples_split	[4, 6, 8, 12]	4	12
LGBM	n_estimators	[100, 200, 300, 400]	400	200, 400
	max_depth	[5, 10, 15, 20]	15, 10	10, 5
	num_leaves	[10, 20, 30]	30, 20	10
	min_child_samples	[5, 7, 10, 20, 30]	20, 30	20, 30
	learning_rate	[0.03, 0.05, 0.07, 0.1]	0.07, 0.1	0.03, 0.1
ANN	boosting_type	[gbdt]	gbdt	gbdt
	activation	[relu, tanh]	tanh, relu	relu
	hidden_layer_sizes	[(50), (50, 25), (50, 50), (75), (75, 50), (75, 75), (100), (100, 50), (100, 100), (150), (150, 100), (150, 150), (200), (200, 100), (200, 200)]	(200, 200)	50

\*Optimized hyperparameters are indicated in red and blue fonts according to input characteristics 1 and 2, respectively. If the values are the same, they are indicated in black font.

향상을 위한 정교한 튜닝은 자제하였고, 참고문헌을 조사하여 일반적 수준의 하이퍼 파라미터 튜닝을 적용하였다. 하이퍼 파라미터 튜닝은 그리드 서치를 이용하였고, 모델의 과적합을 막기 위한 교차 검증은 10분과 1일 자료 군에 각각 수행하였다. 10분 자료는 11,688개의 인스턴스로 구성되어 있으며 k-fold (K=10, 80%-20% train-test split) CV를 사용하였다. 1일 자료는 163개의 인스턴스로 구성되어 있으며, 폴드 개수가 훈련 샘플 개수와 같은 Leave-One-Out CV를 사용하였다. 일반적으로 k-fold CV는 10겹 교차 검증이 가장 뛰어난 편향-분산 트레이드 오프(trade-off)를 가진다고 알려져 있으며[96], Leave-One-Out CV는 작은 자료 군을 사용할 때 권장된다[97].

Table 3.2는 ML 알고리즘별 하이퍼파라미터 설정 정보를 나타낸다. 하이퍼파라미터 설정 항목, 교차 검증을 위한 리스트 및 데이터 세트에 따른 최적화된 설정값을 나타낸다. 최적화된 하이퍼파라미터를 이용하여 DBWF의 에너지 생산량 예측을 수행하였다(4.2절과 4.3절).

Table 3.3은 ML 알고리즘의 예측 정확도를 평가하기 위해, 사용된 평가 지표이다. 4개의 평가 지표를 활용하여 모델들의 예측 정확도를 산출하였고, 이를 바탕으로 가장 우수한 성능을 보인 모델을 선택하였다.

Table. 3.3 Prediction performance evaluation index for ML algorithms.

Evaluation metric	Description	Equation
RMSE	Root mean squared error로 MSE에 루트를 적용한 값. MSE 값은 오류의 제곱을 구하므로 실제 오류 평균보다 더 커지는 특성이 있어 이에 루트를 적용함	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$
MAE	Mean absolute error로 실제값과 예측값의 차이를 절대값으로 변환한 후 평균한 값	$\frac{1}{n} \sum_{i=1}^n  y_i - \hat{y}_i $
MSE	Mean squared error로 실제값과 예측값의 차이를 제곱한 후 평균한 값	$\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
R2	실제값의 분산 대비 예측값의 분산 비율을 나타내며, 1에 가까울수록 예측 정확도가 높음	$1 - \frac{SS_{res}}{SS_{tot}}$

### 3.4 기상요인 예측 기여도 계산

기상요인 예측 기여도 평가를 위해, Table 3.1의 그룹1과 2를 조합하여 입력 피쳐 1과 2를 구성하였다. 입력 피쳐1은 그룹1의 6개 기상요인과 같고, 입력 피쳐2는 그룹1과 2가 결합한 총 13개의 기상요인으로 구성하였다.

- **Input features 1:** WS80m, WD78.5m, T, Pamb, RH, WSE
- **Input features 2:** WS80m, WD78.5m, T, Pamb, RH, WSE, TKE75m, TKE50m, eps75m, eps50m, TI80m, TI40m, Ri

분석에 사용된 자료 군은 10분 평균자료와 1일 평균자료이다. 전자는 6개의 기상요인으로 15기 풍력터빈의 출력 합[kW]을 예측하였고, 후자는 13개의 기상요인으로 풍력 발전단지의 1일 발전량[kWh]을 예측하였다. 이 두 가지 자료 군을 기반으로 4가지 ML 알고리즘(SVM, RF, LGBM, ANN)을 이용하여 예측 정확도를 산출하였다. 다음, 가장 우수한 성능을 보인 모델을 판별한 후, 모델의 결과물에 설명 가능한 인공지능 기법(eXplainable Artificial Intelligence, XAI)의 하나인 SHAP 알고리즘을 적용하였다. 이를 통해 풍력 발전단지 에너지 생산량 예측에서 개별 기상요인의 예측 기여도를 산출하고, 이를 평가하였다.

SHapley Additive exPlanations (SHAP)는 샐플리 값과 피쳐 간의 독립성을 핵심 아이디어로 사용하는 XAI 기법이다. SHAP는 예측에 대한 각 피쳐의 기여도를 계산하여 특정 인스턴스의 예측을 설명하는 방법으로, 연합 게임 이론으로부터 샐플리 값을 계산한다[98,99]. 피쳐의 샐플리 값은 가능한 모든 피쳐 값 조합에 대해, 가중 평균한 출력값의 기여도이다. 이 샐플리 값에 의하면 각 피쳐의 기여도는 그 피쳐의 기여도를 제외했을 때, 출력값의 변화 정도로 나타낼 수 있다. 따라서, 전체 출력값을 산출하는 데 있어 각 피쳐가 얼마나 공헌했는지를 설명을 가능하게 한다. 수식은 아래와 같다.

$$\phi_i(v) = \sum_{S \in \mathcal{N} \setminus i} \frac{|S|!(n-|S|-1)!}{n!} (v(S \cup i) - v(S)) \quad (12)$$

여기서,  $n$ 은 전체 피쳐 수,  $S$ 는  $i$ 번째 피쳐를 제외한 모든 집합,  $i$ 는 설명할 인스턴스의 피쳐 값 벡터,  $V(S)$ 는 하위집합  $S$ 의 피쳐 값이 출력에 공헌한 기여도,  $\phi_i$ 는  $i$ 에 대한 샤프리 값이다. 이를 계산하기 위해 파이썬 SHAP 모듈의 트리 설명체를 이용하였다.

### 3.5 예측 모델의 종류와 구성: 대기안정도와 난류 특성값의 활용

풍력 발전단지에 설치된 대부분의 기상탑은 발전단지 건설 초기에 설치되어, 풍력터빈 출력성능 평가 등을 목적으로 약 2년 정도 운영 후에 철거되는 경우가 많다. 이 기간에 일반적으로 기상탑에서 운영되는 바람 센서는 풍속계, 풍향계, 온·습도계 및 압력계 등이다. 대기안정도와 난류 특성값을 취득할 수 있는 3차원 초음파 풍향·풍속계를 운영하는 경우는 거의 없다. 해당 장비는 고가일 뿐만 아니라 설치 후에 장기간 측정 성능을 유지하며 운영하기에는 어려운 점이 많기 때문이다. 또한, 연구 목적 이외의 목적성(예, 상업적)을 찾기 힘들기 때문이다. 이와 같은 상황에서 유용하게 활용될 수 있는 것이 바로 대기안정도와 난류 특성값을 예측하는 모델이다. 이 예측 모델은 풍력 발전단지 건설 초기 3차원 초음파 풍향·풍속계의 1~2년 치 측정자료를 바탕으로 구축된다. 이는 풍속, 풍향, 온도, 습도, 압력, 풍속전단지수를 입력 피쳐로 대기안정도와 난류 특성값을 예측하는 모델이다. 이를 활용하면 기상탑 또는 3차원 초음파 풍향·풍속계의 철거한 후에도 대기안정도와 난류 특성값의 예측이 가능하다. 또한, 풍력 발전단지 에너지 생산량 예측 모델에 접목해 활용할 수 있는 실용성을 제공한다.

본 연구에서는 LGBM과 DBWF의 측정자료를 기반으로 대기안정도와 난류 특성값을 예측하는 모델을 구축하였다(Fig. 3.2 참조). 모델 구축에 사용된 측정자료 기간은 2016년 03월~2017년 02월이다. 해당 모델(Fig. 3.2b ② ML model)은 DBWF 에너지 생산량 예측 모델(Fig. 3.2b ① ML model)의 하위 모델로써 이를 적용하기 전·후의 에너지 생산량 예측 정확도를 평가하였다.

정확도 평가를 위한 자료는 모델 구축과정에서 한 번도 노출된 적이 없는 2017년 04월~2017년 11월의 측정자료를 이용하였다. 이 기간은 3차원 초음파 풍향·풍속계가 철거되어, 대기안정도와 난류 특성값 자료를 확보할 수 없는 기간이

다. 따라서, 이 기간에는 구축된 모델로 대기안정도와 난류 특성값을 예측하고, 이 예측된 값과 그 외의 기상요인의 실측값을 이용하여 DBWF의 1일 발전량을 예측하였다.

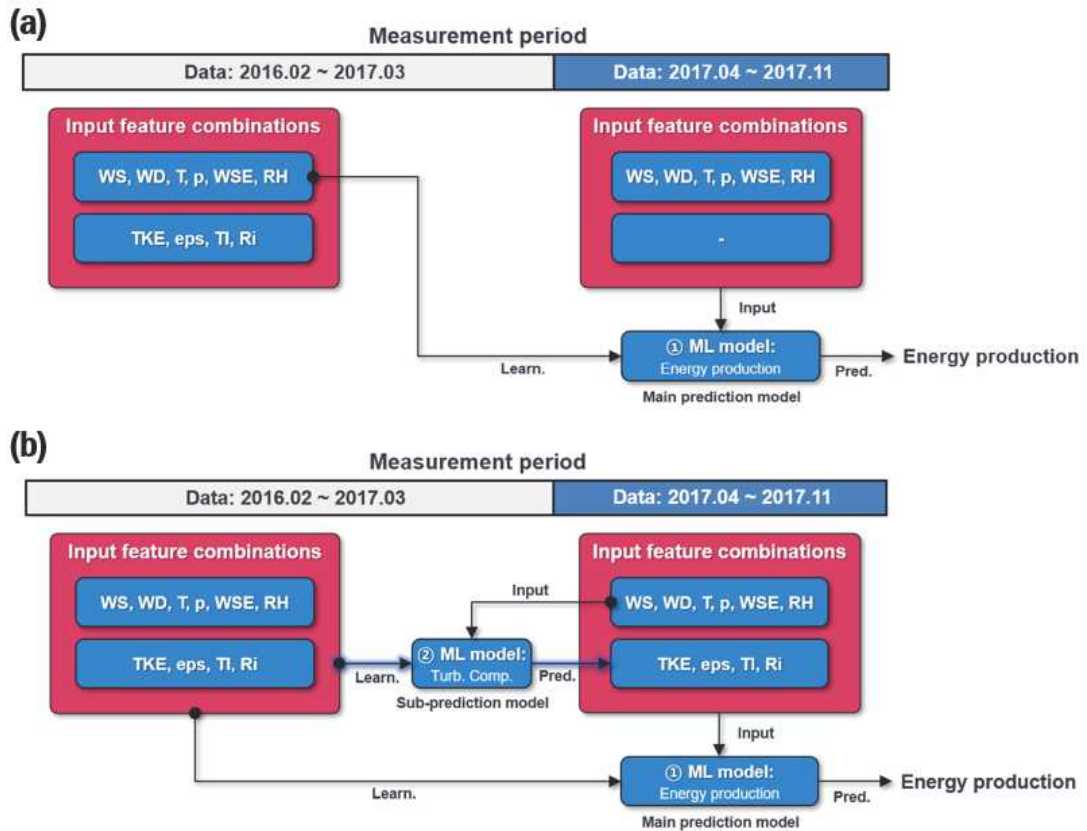


Fig. 3.2 Flow chart for building and applying the predictive model of atmospheric stability and turbulence parameters: Before (a) and after (b) the application of the estimator(① ML model) to the energy production prediction model(② ML model). The period of data used to build the estimator is from 2016.02 to 2017.03. Using this estimator, we predicted the turbulence components from 2017.04 to 2017.11. The energy production of wind farm was predicted using the predicted values of the turbulence component and the measured values of other meteorological factors during this period as input features.

대기안정도와 난류 특성값은 예측값을 그 외 기상요인의 실제값을 사용하였으며, 이를 조합하여 모델을 구성하였다. 최종적으로 DBWF의 10분 평균 출력과 1일 발전량 예측을 위한 모델링은 각각 6가지로 하였다(Table. 3.4).

Table. 3.4 Models for evaluating the prediction accuracy of DBWF energy production. Energy production prediction models 1 to 4 did not consider atmospheric stability and turbulence parameters, and models 5 and 6 were considered.

Predictive model No.	Input feature configuration	
	Meteorological factors used as measured values	Meteorological factors calculated by sub-prediction models
1	WS, WD, T, P, WSE, RH	-
2	WS, WD, T, P, WSE, RH, TI40m	-
3	WS, WD, T, P, WSE, RH, TI80m	-
4	WS, WD, T, P, WSE, RH, TI40m, TI80m	-
5	WS, WD, T, P, WSE, RH	TKE75m, TKE50m, eps75m, eps50m, Ri, TI80m, TI40m
6	WS, WD, T, P, WSE, RH, TI40m, TI80m	TKE75m, TKE50m, eps75m, eps50m, Ri

\*WS: wind speed/WD: wind direction/T: temperature/P: pressure/  
RH: relative humidity/TI: turbulence intensity/TKE: turbulence kinetic energy/  
eps: turbulence dissipation rate/Ri: Richardson number.

에너지 생산량 예측 모델 1은 일반적으로 활용되는 기상요인 6개로 구성하였다. 이를 바탕으로 모델 2~4는 40m와 80m 높이의 TI를 추가하였다. TI는 컵형 풍속계에서 취득된 10 평균 풍속과 표준편차를 이용하여 계산할 수 있기에 별도의 3차원 풍향·풍속계를 설치하지 않고도, 기존 관측 장비만으로 산출할 수 있는 변수이다. 따라서, 난류 특성값 중 TI는 별도의 예측 모델을 통해 예측하지 않아도 실측값으로 대체 활용이 가능하다. 이 점을 고려하여, TI 포함 여부에 따라 모델 2~4를 구성하였다. 모델 5와 6은 하위 예측 모델에 의해 예측된 대기안 정도와 난류 특성값을 활용한 에너지 생산량 예측 모델이며, 난류성분의 개수에 따라 구분하였다. 최종적으로 모델 1~4와 모델 5, 6은 각각 하위 예측 모델 적용 전·후 DBWF의 10분 평균 출력 및 1일 발전량 예측 모델이다.

성능 평가 지표는 RMSE, MAE, MSE 및 R2를 사용하였으며, 수식 및 세부 설명은 Table 3.3을 참고 바란다.



## IV. 풍력 발전단지 에너지 생산량 예측 정확도 평가

### 4.1 기상요인에 의한 풍력터빈의 출력 특성과 연간발전량 변화

#### 4.1.1 기상요인 분포 특성

대기안정도의 레짐에 따른 7가지 기상요인의 분포 형태를 분석하였다. 레짐은 Ri를 이용하여 강한 불안정, 중간 불안정, 약한 불안정, 중립 및 안정상태로 분류하였고, 7가지 기상요인은 다음과 같다.

##### 1) 풍속전단지수

Fig. 4.1은 대기안정도 변화에 따른 WSE의 산포 특성을 나타낸다. 또한, 분류된 대기안정도에 따라 각 매개변수의 통계 특성을 상자 그림(Box plot)으로 도시하였다. 이를 통해 대기안정도 간의 유의한 차이점을 판별하고자 하였다.

Ri의 값이 큰 중립상태(near-neutral)인 0에서 양의 값으로 진행될수록 대기는 보다 안정상태로 성층화된다. 대기가 안정해질수록 WSE도 점점 증가하여, 안정상태는 전체 대기안정도 중에서 가장 높은 WSE 분포를 보인다. 안정상태의 상자 그림을 살펴보면, WSE의 평균값, 제1사분위수(25%) 및 제3사분위수(75%)의 값은 각각 0.49, 0.38 및 0.59를 보인다. 또한, 최소값과 최대값은 각각 -0.28과 0.97을 보인다. 안정상태의 대기는 중립상태의 대기와 유사한 분포를 보이지만 최소값과 최대값에서 보다 넓은 분포범위를 나타낸다.

Ri의 값이 0에서 음의 값으로 진행될수록 대기는 보다 불안정상태로 성층화된다. 대기가 강한 불안정상태로 진전될수록 WSE의 분포는 감소 경향을 보이며, 상자 그림의 WSE 평균값은 0.47(n), 0.41(u1), 0.36(u2) 및 0.29(u3)를 보인다. 대기상태가 불안정 레짐일 때는 기타 레짐보다 낮은 규모의 WSE를 보이며, 이상치의 출현 빈도가 급격히 높아진다. 또한, 대기가 안정에서 강한 불안정상태로 변화되면서 WSE는 평균적으로 0.2가 감소하여, 연직 구배가 감소한 윈드 프로파일의 형성이 형성되는 것을 알 수 있다.

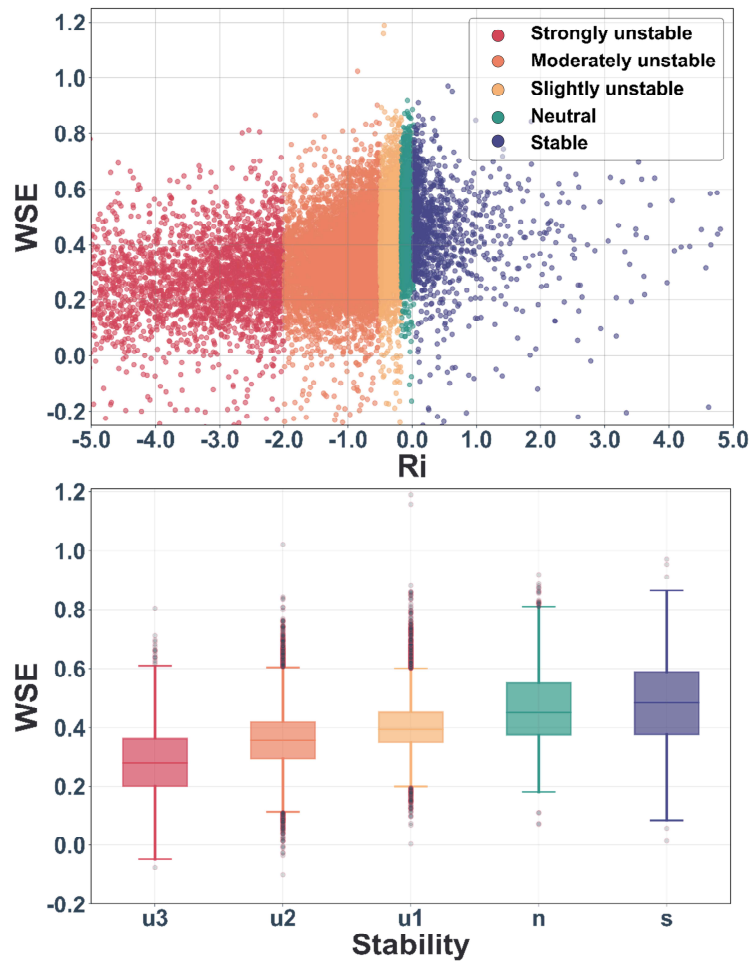


Fig. 4.1 Scatter diagram (top) and box plot (bottom) of wind shear exponent (WSE) according to the change in atmospheric stability. The range of atmospheric stability is from -5.0 to 5.0. WSE is based on the wind speed data at 40m and 80m heights. Ri-Richardson number, u3 - strongly unstable, u2 - moderately unstable, u1 - slightly unstable, n - neutral, and s-stable.

## 2) 풍속

Fig. 4.2는 대기안정도 변화에 따른 풍속의 산포 특성 및 상자 그림을 나타낸다. 대기가 Ri의 값이 0인 근 중립상태로 성층화될 때, 고풍속의 출현이 눈에 띄게 증가하는 것을 알 수 있다. 특히, 대기가 약한 불안정과 중립상태일 때 고풍속의 출현 빈도가 높다. 이 중에서 약한 불안정상태의 상자 그림을 살펴보면, 풍속의 평균값, 제1사분위수 및 제3사분위수의 값은 각각 10.21, 7.10 및 13.07m/s이다. 또한, 최소값과 최대값은 각각 3.75와 20.88m/s를 보인다.

대기의 성층 상태가 약한 불안정에서 강한 불안정으로 변화할 경우 풍속은 감소 경향을 보인다. 강한 불안정상태의 상자그림 통계치는 평균값, 제1사분위수 및 제3사분위수에 따라 각각 6.14, 5.02 및 7.04m/s을 보인다. 또한, 풍속은 집중된 분포 형태를 보이고 이상치의 빈도수도 증가하는 것을 확인할 수 있다. 한편 대기가 안정상태로 변화할 때도 풍속은 감소 경향을 보인다. 상자 그림에서 안정상태의 평균값은 7.02m/s를 보인다. 대기가 약한 불안정상태일 때 고풍속의 발생 비율이 가장 높지만, 대기가 더욱더 불안정한 상태로 성층화되면 안정상태와 유사한 풍속 분포를 보이는 것으로 나타난다.




Fig. 4.2 Scatter diagram (top) and box plot (bottom) of wind speed according to the atmospheric stability. The range of atmospheric stability is from  $-5.0$  to  $5.0$ . Wind speed is based on the measurements of the cup anemometer mounted at 80m height on the meteorological mast. Ri-Richardson number, u3 - strongly unstable, u2 - moderately unstable, u1 - slightly unstable, n - neutral, and s - stable.

### 3) 난류강도

Fig. 4.3은 대기안정도 변화에 따른 TI의 산포 특성 및 상자 그림을 나타낸다. TI의 분포를 살펴보면, 전반적으로 불안정 레짐이 기타 레짐에 비해 TI가 높음을 알 수 있다. Ri가 0에서 음수 방향으로 대기의 불안정성이 더욱더 성층화될수록, 고 TI의 출현이 빈번해지고, TI 분포가 더욱더 산발적 형태를 보인다.




Fig. 4.3 Scatter diagram (top) and box plot (bottom) of turbulence intensity (TI) according to the change in atmospheric stability. The range of atmospheric stability is from  $-5.0$  to  $5.0$ . For TI, the measurements of the cup anemometers installed at  $80\text{m}$  height on a meteorological mast. Ri-Richardson number, u3 - strongly unstable, u2 - moderately unstable, u1 - slightly unstable, n - neutral, and s - stable.

상자 그림을 살펴보면, TI의 평균값은 0.09(s), 0.11(n), 0.13(u1), 0.14(u2) 및 0.15(u3)를 보인다. 대기가 안정에서 강한 불안정상태로 변화하면서 TI가 점진적으로 증가함을 알 수 있다. 특히, 고 TI의 비율이 가장 높은 강한 불안정상태의 제1사분위수와 제3사분위수는 각각 0.12와 0.18로 나타난다. 추가적으로 대기가 불안정 레짐일 때는 이상치의 출현 빈도가 높게 나타남을 알 수 있다. 반면 저 TI의 비율이 가장 높은 안정 상태는 0.04(제1사분위수) 및 0.13(제3사분위수)을 보인다. 안정상태는 중립상태와 유사한 최대·최소값을 보이나 저 TI의 출현 빈도가 보다 높다.

일반적으로 대기의 성층 상태가 불안정일 때는 지표 근처의 열적 요인에 의한 연직 교환 운동량이 강하게 나타난다. 이 현상은 유동장의 난류 수송 및 혼합과 같은 메커니즘에 직접적인 작용을 한다. 관측자료를 기반으로 한 참고문헌에 따르면, TI는 보편적으로 야간 경계층(안정상태) 내에서 10% 미만이고, 근 중립 지표층 내에서는 10~15%이며, 불안정 및 대류 경계층(CBL) 내에서는 15% 이상을 보인다[33]. 이처럼 대기의 안정도가 안정에서 중립상태를 거쳐 강한 불안정상태로 변화하면서, TI가 점진적으로 증가하는 특징은 본 연구의 DBWF 사이트에서도 확인할 수 있다.

#### 4) 수직 풍속

Fig. 4.4는 대기안정도 변화에 따른 수직풍의 산포 특성 및 상자 그림을 나타낸다. 이때 수직풍은 75m 높이의 3차원 풍향·풍속계에서 취득된 바람 성분인이다. 우선 수직풍의 분포 형태를 살펴보면, 중립상태일 때 수직풍의 양의 값과 음의 값이 가장 넓은 분포범위를 보인다. 대기가 중립에서 강한 불안정상태로 변화되면서, 수직풍의 분포는 양의 값으로 편중되고 더욱더 산발적 형태를 보인다. 반면, 대기가 중립에서 안정상태로 변화되면서, 수직풍의 분포는 음의 값으로 편중되고 보다 집중된 형태를 보인다.

다음, 상자 그림을 살펴보면, 전반적으로 불안정 레짐에서의 수직풍은 양의 값에 치우쳐져 있다. 수직풍의 양수는 상승기류를 의미하며, 근소한 차이기는 하나 약한 불안정으로 성층된 흐름 내에서 그 수치가 가장 높다. 약한 불안정상태의 평균값, 제1사분위수 및 제3사분위수는 각각 0.16, 0.004 및 0.31m/s로 나타난다.

다. 반면, 안정상태에서의 수직풍은 음의 값에 치우쳐져 있다. 수직풍의 음수는 하강기류를 의미하며, 전술한 순서대로 각각  $-0.07$ ,  $-0.25$  및  $0.07\text{m/s}$ 를 보인다. 중립 대기상태에서의 수직풍은 양수 또는 음수로의 편중성이 가장 적었다. 중립 대기상태에서의 통계치는 전술한 순서대로 각각  $0.09$ ,  $-0.68$  및  $1.66\text{m/s}$ 를 보인다. 이를 통해 중립상태는 상승류와 하강류의 혼재 비율이 가장 높을 것으로 나타난다.




Fig. 4.4 Scatter plot (top) and box plot (bottom) of vertical wind according to atmospheric stability. The range of atmospheric stability is from  $-5.0$  to  $5.0$ . For the vertical wind, the measurements of the 3D sonic anemometer installed at  $75\text{m}$  height on the meteorological mast were used. Ri - Richardson number, u3 - strongly unstable, u2 - moderately unstable, u1 - slightly unstable, n - neutral, and s - stable.

### 5) 난류운동에너지

Fig. 4.5는 대기안정도 레짐에 따른 TKE의 산포 특성 및 상자 그림을 나타낸다. Ri의 값이 큰 중립상태인 0에서 양의 값으로 진행될수록 대기는 보다 안정상태로 성층화되고, 대기가 안정화될수록 TKE는 감소한다. 전체 대기안정도 중에서 안정 레짐일 때, 낮은 규모의 TKE 출현빈도가 높다.

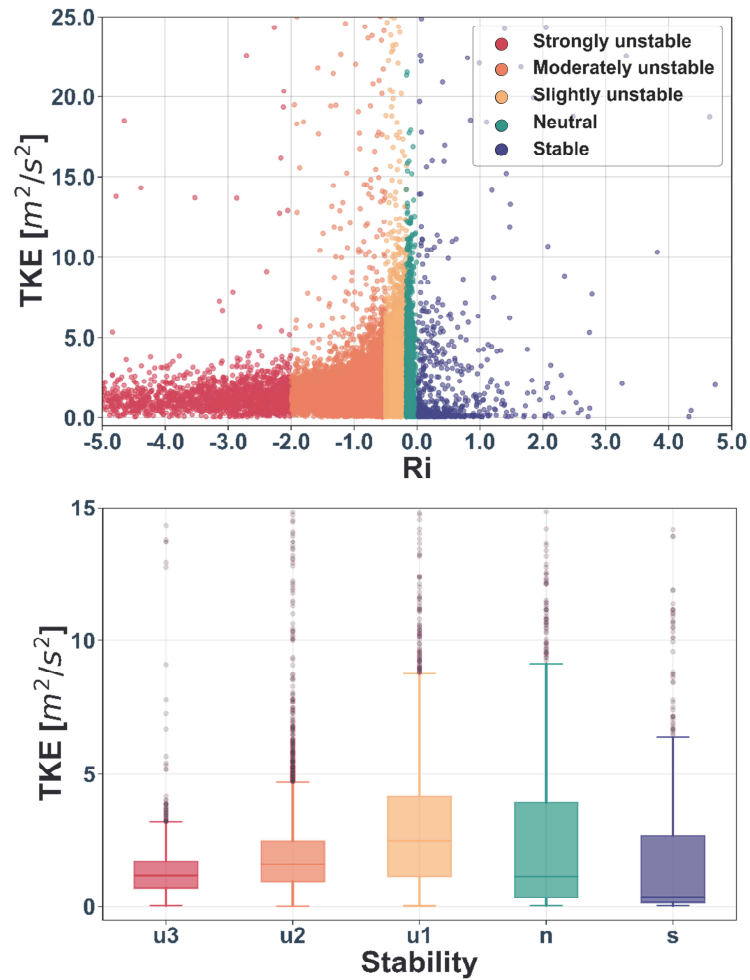


Fig. 4.5 Scatter plot (top) and box plot (bottom) of turbulent kinetic energy (TKE) according to atmospheric stability. The range of atmospheric stability is from  $-5.0$  to  $5.0$ . For the TKE, the measurements of the 3D sonic anemometer installed at 75m height on the meteorological mast were used. Ri - Richardson number, u3 - strongly unstable, u2 - moderately unstable, u1 - slightly unstable, n - neutral, and s - stable.



안정 레짐의 상자 그림을 보면, TKE의 중위값, 제1사분위수(25 %) 및 제3사분위수(75 %)의 값은 각각 0.36, 0.15 및  $2.64\text{m}^2/\text{s}^2$ 을 보인다. 반면, Ri의 값이 0에서 음의 값으로 진행될수록 대기는 불안정한 상태로 성층화된다. 특히, 대기가 약한 불안정 레짐일 때, 고 TKE의 출현 빈도가 급격하게 증가한다. 이때의 상자 그림은 상기의 순서대로 각각 2.46, 1.10 및  $4.17\text{m}^2/\text{s}^2$ 로 극값을 보이고, 이후 대기가 더욱 강한 불안정상태로 진전될수록, 낮은 수준의 TKE 분포를 보인다.

Fig. 4.6은 수평풍 변화에 따른 수직풍을 대기안정도 별로 나타낸 것이다. 지표면 50m 높이의 경우(Fig. 4.6a), 수직풍은 특정 풍속 구간( $3\sim 4\text{m/s}$ ,  $9\sim 10.5\text{m/s}$ )에서 부분적으로 음수를 나타내지만, 전체적으로 양수에 편중되어있다. 풍력터빈의 시동 풍속 구간에서는 강한 불안정이  $0.12\text{m/s}$ 로 가장 높은 수직풍을 보인다. 풍속이 증가하면서  $6.5\text{m/s}$  풍속 구간에서는 오히려 안정 대기상태가  $0.23\text{m/s}$ 로 가장 높은 값을 보인다. 이 이후부터 정격풍속까지는 일부 구간( $11\text{m/s}$ )을 제외하고, 대기가 중립, 약한 불안정 및 중간 불안정상태일 때 보다 높은 수직풍이 관측된다.

지표면 75m 높이의 경우(Fig. 4.6b), 안정 대기상태의 수직풍은 시동풍속에서  $8\text{m/s}$ 까지 강한 음의 값을 보인다. 이 풍속 구간에서 대기가 중립을 거쳐 불안정 레짐으로 성층화될 때, 수직풍은 양의 값으로 변화하는 것을 알 수 있다. 이를 통해 해당 풍속구간은 대기안정도 변화에 따라 상승류와 하강류가 혼재하는 구간임을 확인할 수 있다. 또한, 대기상태에 따라 수직풍의 차이가 가장 큰 구간이기도 하다. 이 이후부터 정격풍속까지는 수직풍이 양의 값을 보이고 대기상태에 따른 풍속 차이는 감소한다.

일반적으로 기상탑의 컵형 풍속계를 이용하여 풍속자료를 측정할 경우, 수평풍만을 측정하게 된다. 하지만, 실제 사이트에서는 수직풍이 존재하며 이는 하강기류 또는 상승기류로 나타난다. 따라서, 실질적인 바람은 수평과 수직 속도 성분의 결합된 형태로 그 흐름이 형성된다. 이를 3축 방향 풍속 성분의 벡터 합으로 표현할 수 있고 벡터 합을 통해 풍속의 방향과 양이 변동하게 된다. 즉, 연직풍의 고려는 바람의 이류가 상승·하강류와 같은 대류와 결합하여 풍량의 증감으로 이어질 수 있음을 의미한다.

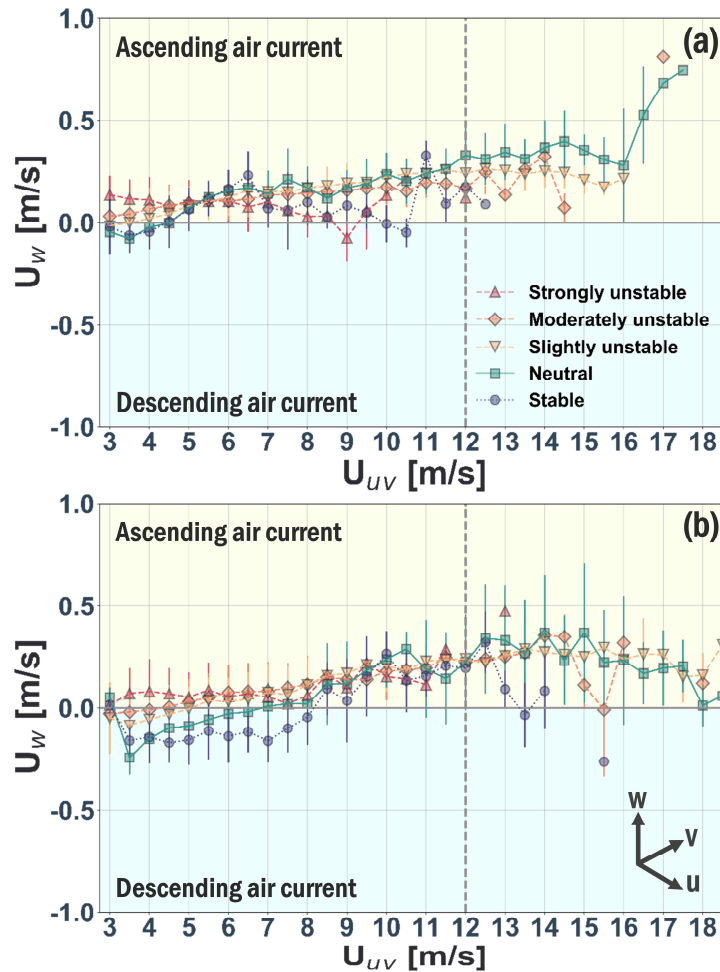


Fig. 4.6 Vertical wind according to the horizontal wind for each atmospheric stability condition: (a) 50m height and (b) 75m height. For horizontal wind and vertical wind, the measurement data of the 3D sonic anemometer were used. u - streamwise, v - lateral, and w - vertical.

관측 기간 동안 DBWF의 연 평균 풍속은 6.02m/s이다. 이 풍속 구간에서는 대기가 불안정 레짐일 때, 지표면 50m와 75m 높이 모두 상승기류가 발생하는 것을 알 수 있다. 이를 통해 동질 한 상승 흐름에서 유발된 운동량이 풍력터빈의 회전 면적에 유입되어 풍력터빈에 전달될 것으로 추정된다. 반면, 대기가 안정 레짐일 때, 지표면 50m에서는 상승류가 우세하지만, 75m 높이에서는 하강류가 지배적이다. 각 높이에서 보이는 상이한 기류는 결합과정에서 비 동질 흐름을 형성하고 이로 인해 감소된 운동량이 풍력터빈에 유입될 것으로 판단된다. 이때 감

소된 운동량은 풍속 저감을 의미하며, 풍력터빈이 출력을 발생시키는 에너지 변환과정에 영향을 미칠 수 있다.

## 6) 난류소산율

대기안정도 변화에 따른  $\varepsilon$ 의 산포 특성을 분석하였고, 대기안정도의 레짐별 통계 특성을 상자 그림으로 도시하였다(Fig. 4.7). 이 분석을 통해 레짐에 따른  $\varepsilon$ 의 유의한 차이점을 판별하고자 한다.

Ri의 값이 0에 가까운 근 중립상태일 때,  $\varepsilon$ 의 규모는  $10^{-5} \sim 10^1 \text{m}^2/\text{s}^3$ 으로 가장 넓은 분포범위를 보인다. Ri가 0에서 양의 값으로 진행될수록 대기는 보다 안정상태로 성층화된다. 대기가 안정해질수록  $\varepsilon$ 은 산발적 분포를 보이며, 낮은 규모(약  $10^{-3}$  이하)의  $\varepsilon$  출현 빈도가 급격히 높아진다. 안정 레짐의 상자 그림을 살펴보면,  $\varepsilon$ 의 중위값, 제1사분위수(25%) 및 제3사분위수(75%)의 값은 각각 0.0015, 0.0004 및  $0.0088 \text{m}^2/\text{s}^3$ 을 보인다.

Ri의 값이 0에서 음의 값으로 진행될수록 대기는 보다 불안정상태로 성층화된다. 대기가 강한 불안정 레짐으로 진전될수록  $\varepsilon$ 은 점진적 감소와 집중된 분포 형태를 보인다. 전반적으로 약한 불안정 레짐일 때, 강한 수준의  $\varepsilon$  출현 빈도가 높다. 이때의 상자 그림을 살펴보면,  $\varepsilon$ 의 중위값, 제1사분위수(25%) 및 제3사분위수(75%)의 값은 각각 0.0198, 0.0074 및  $0.0370 \text{m}^2/\text{s}^3$ 을 보인다. 평균적으로 불안정 조건이 안정조건보다  $\varepsilon$ 이 1~2차수 높은 수준을 보인다. 불안정으로 성층화된 대기는 강화된 대류 특성을 보인다[33]. 강한 대류 조건에서는 양의 부력과 관련된 난류 수준이 향상되어, 유동 변동성이 증가하기 때문에  $\varepsilon$ 이 높게 나타난 것으로 풀이된다. 이러한 점은 대기가 불안정 레짐일 때, 난류로 소산되는 힘이 보다 강하다는 것을 의미한다.

Fig. 4.8은 수평 풍속 변화에 따른 대기안정도의 레짐별  $\varepsilon$ 곡선을 나타낸다.  $\varepsilon$ 은 75m보다 50m 높이에서 더욱 큰 규모를 보이고, 두 군데 측정 높이 모두 불안정 레짐이 안정 레짐보다 높은 값을 보인다. 특히, 약한 불안정 레짐에서  $\varepsilon$  곡선의 범위는  $10^{-2} \sim 10^{-1} \text{m}^2/\text{s}^3$ 으로 가장 높은 규모를 보인다. 안정 레짐의 경우,  $\varepsilon$  곡선은 1~2차수 낮은 범위인  $10^{-4} \sim 10^{-2} \text{m}^2/\text{s}^3$ 에 분포하고 있다.




Fig. 4.7 Scatter plot (top) and box plot (bottom) of the turbulence dissipation rate ( $\varepsilon$ ) according to the atmospheric stability.  $\varepsilon$  was calculated using data measured via the 3D sonic anemometer installed at a height of 75m on the meteorological tower. Atmospheric stability ranged from -5.0 to 5.0. Ri is the Bulk Richardson number, u3 is the strongly unstable regime, u2 is the moderately unstable regime, u1 is the slightly unstable regime, n is the neutral regime, and s is the stable regime.

또한, 저 풍속에서 고풍속으로 진행되면서  $\varepsilon$ 이 증가하지만, 여전히 안정 레짐은 기타 레짐과 약 1차수 수준의 규모 차이가 나타난다. [100]의 연구(그림 14)에서는 수평 풍속에 따른  $\varepsilon$  곡선을 분석하였다.  $\varepsilon$  곡선의 주된 분포는 불안정과 안정 레짐에서 각각  $10^{-3} \sim 10^{-2} \text{m}^2/\text{s}^3$ 와  $10^{-4} \sim 10^{-3} \text{m}^2/\text{s}^3$ 을 보인다. 레짐에 따른  $\varepsilon$ 의 규모 차이는 1차수 수준을 보이고, 풍속증가에 따른 양의 상관관계를 보인다는 점은

본연구결과와 유사하다. 하지만, 전반적인  $\varepsilon$ 의 규모는 DBWF에서 1차수 정도 높게 형성된다.

불안정 조건의  $\varepsilon$  곡선은 약한 불안정, 중간 불안정 및 강한 불안정 순서로 강한 규모를 보인다. 이와 함께 중립 레짐의  $\varepsilon$ 곡선은 강한 불안정과 약한 불안정 사이에 형성되어있으며, 중립상태  $\varepsilon$  곡선의 특이점은 6~7m/s를 전·후로 보다 급격한 증가세를 보인다는 점이다. 이 이상의 풍속 구간에서는 약한 불안정의  $\varepsilon$  곡선과 높은 접합도를 보이며 두 대기 레짐의  $\varepsilon$  곡선에서 유의미한 차이는 확인되지 않는다.

안정 레짐의  $\varepsilon$  곡선은 7m/s(50m)와 9m/s(75m)를 초과하는 풍속 구간에서 수집된 자료가 부족하여 그래프로 표출하지 못했다. 다만 풍속의 증가와 함께 레짐간에 차이가 줄어드는 경향은 확인할 수 있다. 이를 감안하면, 고풍속으로 진행될수록 안정 레짐과 기타 레짐 간의  $\varepsilon$  차이가 감소될 것으로 추정된다.

두 군데 측정지점은 풍력터빈(허브높이 80m)의 회전 면적 내에 위치하며, 두 지점 사이의  $\varepsilon$  차이는 안정 레짐이 불안정 레짐보다 크다. 불안정 레짐에서는 50m와 75m 높이에서  $\varepsilon$ 이 약 1차수 이내의 변동성을 보인다. 두 측정지점의 유동 흐름이 결합하여 회전 면적으로 유입되는 과정에서, 난류로 흩어지는 힘이 유사한 수준을 보인다. 이는 동질한 유동장이 형성됨을 의미한다. 반면, 안정 레짐에서는 50m와 75m 높이에서  $\varepsilon$ 이 약 1차수 이상의 변동성을 보인다. 두 측정지점의 유동 흐름이 결합하여 회전 면적으로 유입될 때, 난류로 흩어지는 힘이 상이한 수준을 보인다. 이는 비 동질한 유동장이 형성됨을 의미한다. 이를 통해 불안정 레짐과 안정 레짐은  $\varepsilon$ 에서 정량적 차이를 보이는 유동장이 형성될 것으로 판단된다.

일반적으로 대기안정도 변화는 난류 특성을 변화시키고 풍력터빈의 성능에 영향을 미치는 것으로 알려져 있다[101,102]. 또한 Fig. 4.7의 분석 결과, 레짐에 따라  $\varepsilon$ 은 규모 차이를 보이는 것으로 나타난다. 이러한 점들을 감안하면,  $\varepsilon$ 의 물리적 성질에 기인한 운동량 증감은 풍력터빈의 운동에너지 추출과정에 영향을 미칠 수 있음을 강하게 시사한다.

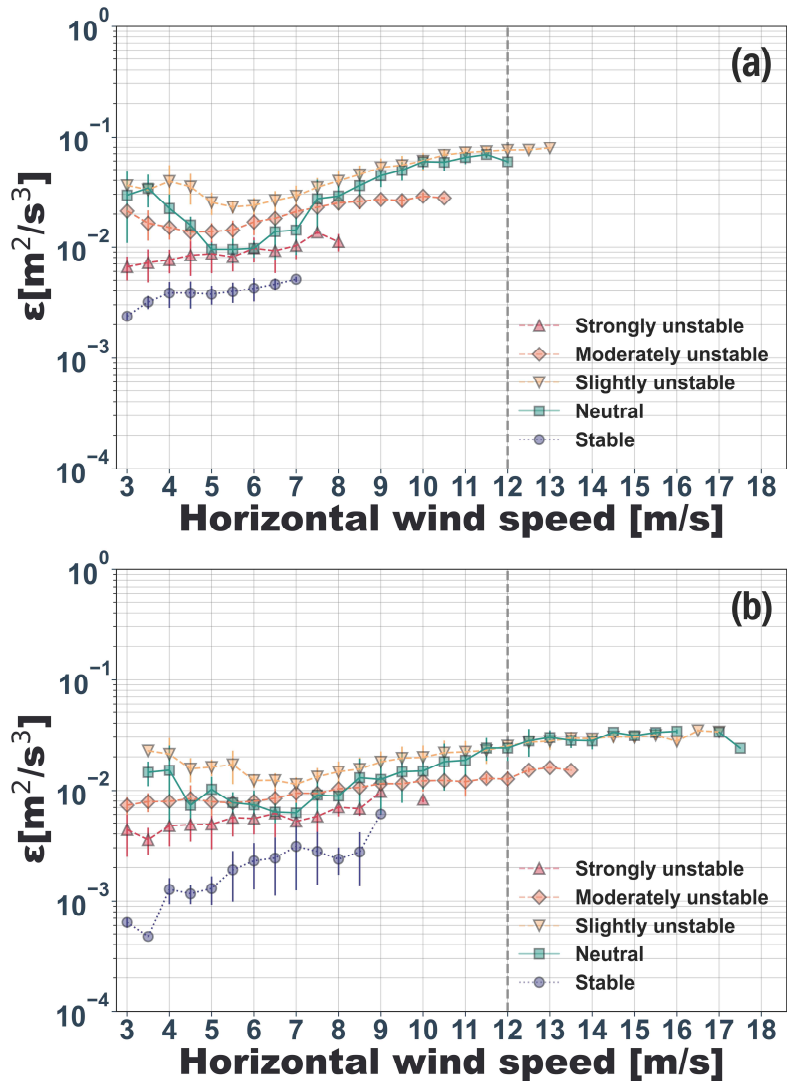


Fig. 4.8 Turbulence dissipation rate ( $\varepsilon$ ) curve according to the horizontal wind speed for each atmospheric stability regime. The horizontal wind speed was, on average, 0.5 m/s, as measured using the 3D sonic anemometers installed at heights of (a) 50m and (b) 75m. For  $\varepsilon$ , the 25–75% quartile data from each atmospheric stability regime were used. The gray dotted line indicates the rated wind speed of the WTG.

#### 4.1.2 단일 풍력터빈의 연간발전량 차이

Fig. 4.9의 좌측 열은 기상요인의 레짐 분류에 따른 출력의 산포도를 나타낸다. 3m/s에서 7m/s까지는 안정 대기상태, 저 TI, 약한 WSE 및 저 TKE의 발생빈도가 높다. 그 이상의 풍속 구간에서는 풍속의 증가와 함께 중립·불안정 대기상태, 고·중 TI, 강한·중간 WSE 및 고·중 TKE의 빈도가 증가한다. 또한, 출력이 분산

되는 경향이 증가하여 정격풍속 이전인 10~11.5m/s 구간에서 가장 큰 출력 변동성을 보인다.

Fig. 4.9의 우측열은 기상요인의 레짐 분류에 따른 출력 곡선을 나타낸다. 시동 풍속 부근(3~5m/s)에서는 유사한 출력을 보여 레짐에 따른 유의미한 차이를 판단하기 어렵다. 6m/s에서 약 9.5m/s 풍속 구간에서는 중간·약한 불안정, 고 TI, 중간 WSE 및 고 TKE가 높은 출력을 보인다. 이 이상의 풍속 구간에서 대기안정 정도의 경우, 부분적으로(10~11m/s) 안정상태가 낮은 출력을 보이기도 하지만, 정격풍속 부근에서는 안정과 불안정상태가 중립상태보다 높은 출력을 보인다. TI의 경우 풍속의 증가와 함께 저 TI의 출력이 높아지고 고 TI는 출력이 감소한다. WSE는 풍속이 증가하면서 강한 WSE가 높은 출력을 보이지만, 기타 기상요인에 비해 레짐 별 출력 곡선의 차이가 크지 않다. TKE는 부분적으로(약 10m/s) 저 TKE가 높은 출력을 보이기도 하지만, 대체로 고 TKE의 출력이 높게 나타난다. 기상요인의 레짐 변화에 따른 출력 곡선의 차이를 보다 명확하게 파악하기 위해 Fig. 4.10의 분석을 수행하였다.



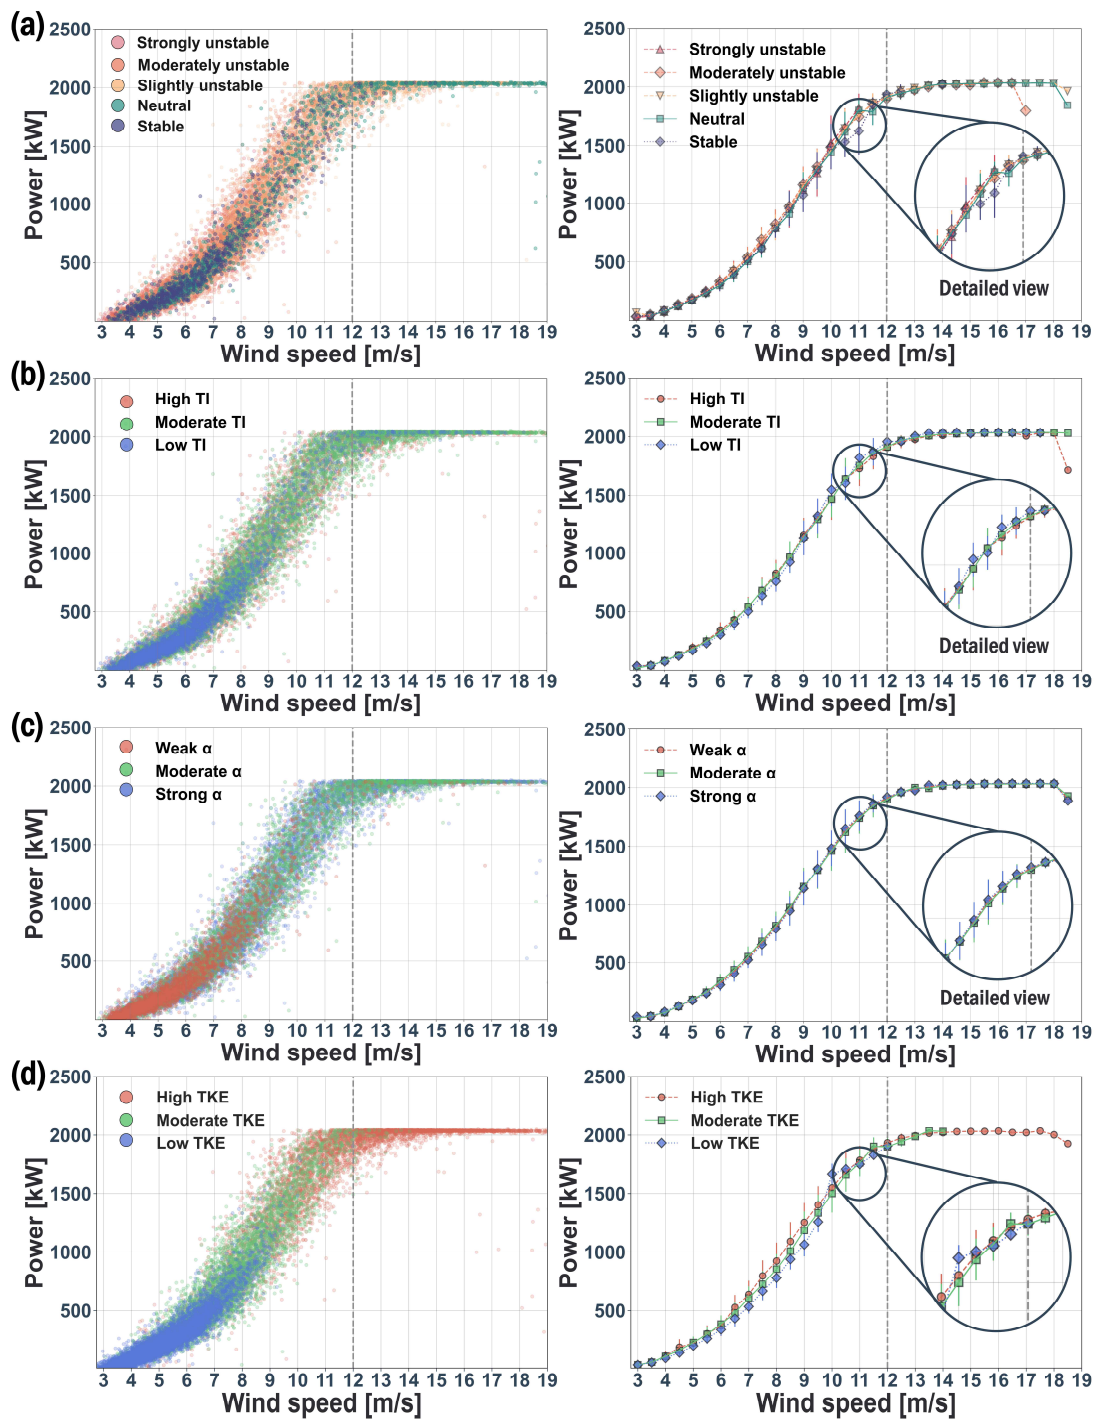


Fig. 4.9 Scatter plots (left column) and power curves (right column) according to the regime using the power data of the 15th wind turbine: (a) atmospheric stability, (b) TI, (c) WSE, and (d) TKE. For power curves, the mean values of the 0.5 m/s section were used. Error bars indicate MAD values. The grey dotted line indicates the rated wind speed of the wind turbine.

Fig. 4.10은 Fig. 4.9에서 각 기상요인의 중간 레짐 출력 곡선을 기반으로 나머지 레짐 출력 곡선과의 차이를 나타낸 것이다.

Fig. 4.10a의 대기안정도의 경우, 평균적으로 불안정 레짐이 안정 레짐보다 높은 출력이 나타남을 알 수 있다. 약 6~9.5m/s 구간에서 중간 불안정이 가장 높은 출력을 보이며 7.5m/s에서 안정상태와는 75kW의 차이를 보인다. 특히, 안정과 강한 불안정상태 사이의 출력 차이는 11m/s에서 약 200kW로 극값을 보이고, 2차 최대값은 10.5m/s에서 131kW로 나타났다. 정격풍속인 12m/s에서는 오히려 안정상태의 출력이 높게 나타난다.

Fig. 4.10b의 TI의 경우, 약 9m/s 이하에서는 고 TI가 높은 출력을 보인다. 이 이상의 풍속에서 정격풍속까지는 저 TI가 부분적으로(10.5m/s) 낮은 출력을 보일 때도 있지만, 대부분 기타 TI 보다 높은 출력을 보인다. 저 TI와 고 TI는 약 9.5m/s를 기점으로 출력성능의 교차가 발생한다. TI 레짐에 따른 최대 출력 차이는 11m/s에서 91kW로 저 TI가 높게 나타났다. 출력의 변동범위는 저 TI와 고 TI에서 각각 -49~79kW와 -32~23kW를 보인다. 저 TI가 보다 큰 출력 변동성을 나타낸다.

Fig. 4.10c의 WSE의 경우, 9m/s 이하에서는 중립 WSE가, 그 이상의 풍속 구간에서 정격풍속까지는 강한 WSE가 높은 출력을 보인다. 약 9.5m/s를 기점으로 강한 WSE의 출력성능이 증가한다. 출력의 변동범위는 약한 WSE와 강한 WSE에서 각각 -17~19kW와 -30~32kW를 보인다.

Fig. 4.10d의 TKE의 경우, 4.5m/s부터 고 TKE가 높은 출력을 보이고, 9.5m/s까지 고·저 TKE 사이의 출력 차이는 계속 증가한다. 최대 출력 차이는 9m/s에서 191kW로 고 TKE가 높게 나타나며, 출력의 변동범위는 저 TKE와 고 TKE에서 각각 -121~168W와 -23~83kW를 보인다.

전반적으로 동일한 풍속 구간이라 할지라도 각 기상요인의 분류된 레짐에 따라 출력 차이는 분명히 존재한다. 약 9~11m/s 풍속 구간에서 레짐에 따른 출력 차이와 중앙 절대 편차가 가장 높았다. 이 구간을 기점으로 풍속의 증가와 함께 출력의 차이와 편차는 감소한다. 약 12m/s 부근에서는 풍력터빈의 정격출력을 생산하는 풍속 구간으로 블레이드의 피치제어를 통해 출력을 일정하게 유지시켜, 기상요인의 레짐 변화에 따른 출력 차이가 반영되지 않는 것으로 풀이된다.

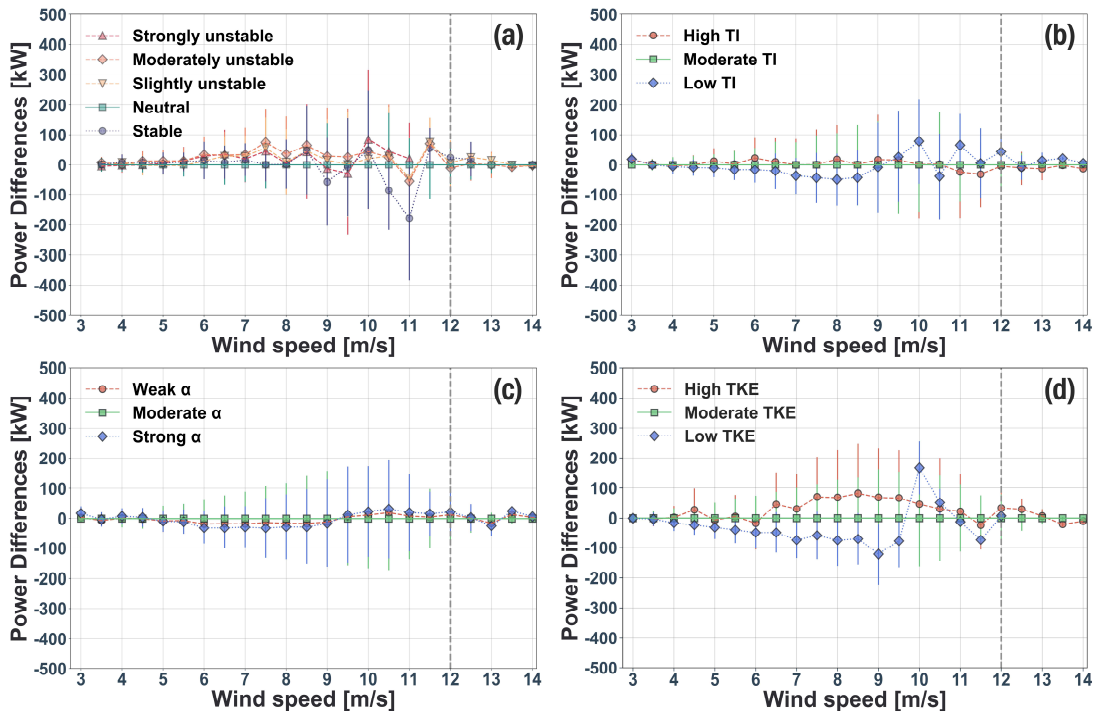


Fig. 4.10 Power differences between regimes of atmospheric factors: (a) atmospheric stability, (b) TI, (c) WSE, and (d) TKE. For power, the average value of the 0.5 m/s wind speed bin was used. Error bars indicate MAD values. The grey dotted line indicates the rated wind speed.

평균적으로 레짐 변화에 따른 출력의 변동 수준은 TKE, 대기안정도, TI 및 WSE 순서로 크게 나타났다. 전반적으로 레짐 별 출력성능의 교차지점은 TKE, TI와 WSE에서 명확하게 확인할 수 있었고, 특히 TKE에서 레짐 별 출력 차이는 가장 크게 나타났다. 이외에, WSE의 경우에는 레짐별 출력의 차이를 뚜렷하게 파악하기에는 그 차이가 미미한 수준으로 나타난다. 이는 본 연구에서 다루는 2 MW 풍력터빈의 회전 면적이 작아 윈드시어의 연직 경도에 따른 출력 차이가 경미하기 때문으로 풀이된다.

기상요인의 레짐 별 출력 곡선과 레일리 분포의 풍속 확률 밀도를 이용하여 AEP를 산출하였다. 레일리 분포의 연평균풍속은 4~12m/s로 가정하였다. 이때, 각 기상요인에서 중간 레짐의 AEP를 기준으로, 기타 레짐에서 계산된 AEP와의 상대 오차를 비교하였다(Fig. 4.11).

Fig. 4.11a의 대기안정도의 경우, 전반적으로 불안정 레짐에서 높은 AEP를 보인다. 가장 높은 AEP는 중간 불안정상태에서 나타났다. 중간 불안정상태는 DBWF의 연 평균 풍속인 6.02m/s에서 중립상태와 약 4.0%의 AEP 차이를 보인다. 또한, 이보다 높은 연 평균 풍속인 6.5m/s에서 안정과 중립 대기상태의 AEP 교차가 발생한다. 이 이후의 연평균풍속에서는 중립이 안정상태보다 약 0.4% 높은 AEP를 나타낸다.

Fig. 4.11b의 TI의 경우, 고 TI가 높은 AEP를 보인다. 사이트의 연 평균 풍속에서는 고 TI와 저 TI 사이에 2.6%의 AEP 차이를 보인다. 연 평균 풍속의 증가에 따라 TI의 레짐 별 AEP 차이는 감소하며, AEP가 약 1% 이하의 차이를 보이는 연 평균 풍속은 약 8.0m/s이다.

Fig. 4.11c의 WSE의 경우, 중간 WSE에서 높은 AEP를 보인다. 중립 레짐 이외에 약한 WSE가 강한 WSE보다 높은 AEP를 보인다. 사이트의 연 평균 풍속에서는 레짐 변화에 따라 1.4%의 AEP 차이를 보인다. 기타 기상요인과 마찬가지로 연 평균 풍속의 증가와 함께 레짐 간의 AEP 차이는 감소하고, 연 평균 풍속이 약 7m/s 이상부터 1% 미만의 AEP 차이를 보인다.

Fig. 4.11d의 TKE의 경우, 고 TKE가 높은 AEP를 보인다. DBWF의 연평균풍속에서는 고·저 TKE 사이에 약 8.6%의 AEP 차이를 보인다. 연평균풍속의 증가와 함께 차이는 감소하며, 약 9m/s에서부터 5% 미만의 AEP 차이를 보인다.

전체적으로 기상요인의 레짐간 AEP 차이는 연 평균 풍속의 증가와 함께 감소 경향을 보인다. 레짐 변화에 따른 AEP는 TKE, 대기안정도, TI 및 WSE 순서로 큰 차이를 보였다. 이때 AEP 차이는 DBWF의 연 평균 풍속에서 최대 5.0%로 나타났다. 본 연구 사이트와 같은 육상 풍력 발전단지들의 일반적인 연 평균 풍속이 6~7m/s 전·후인 것을 감안한다면, 기상요인의 레짐 변화로 인해 약 5% 수준의 AEP 차이가 유발될 가능성이 있음을 시사한다.

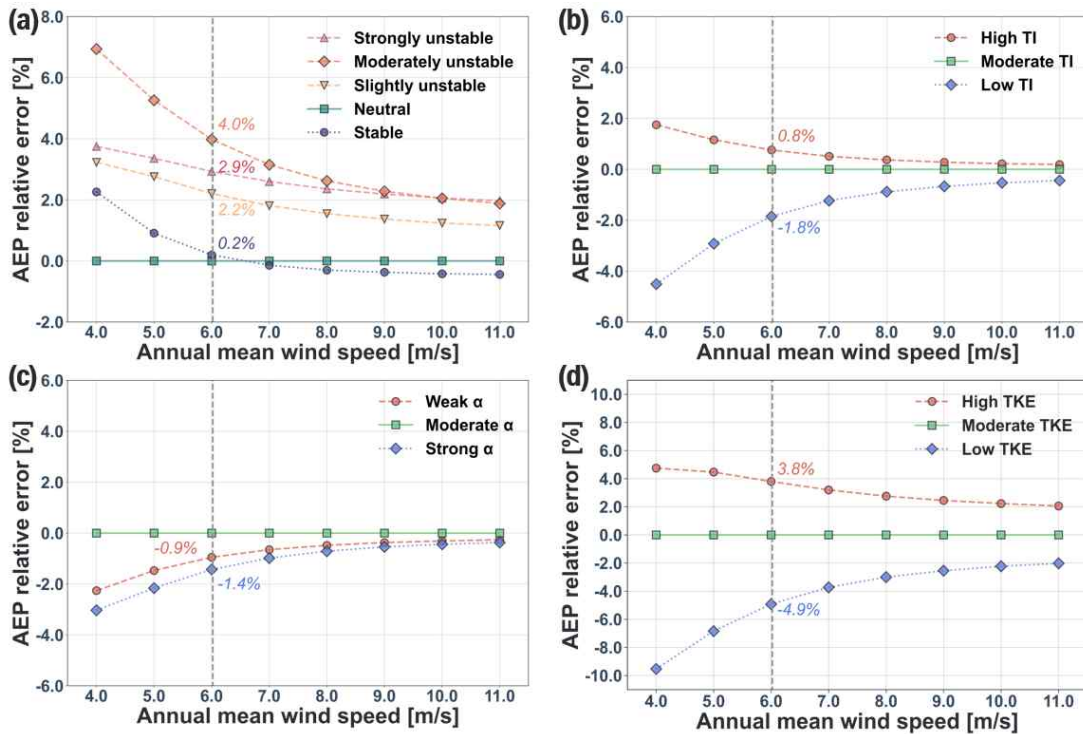


Fig. 4.11 Relative errors of AEP by the regime of atmospheric factors: (a) atmospheric stability, (b) TI, (c) WSE, and (d) TKE. The relative error indicates the difference of the neutral regime with other regimes. The grey dotted line indicates 6.02 m/s, the annual mean wind speed of the DBWF.

### 4.1.3 풍력 발전단지의 연간발전량 차이

Fig. 4.12는 대기안정도 레짐별 정규화된 출력(수식 11 참조)의 빈도수를 나타낸다. 1.0의 정규화된 출력은 자유 유동(Freestream) 영역의 풍력터빈(15번) 출력과 후류(downstream) 영역의 풍력터빈(개별 터빈) 출력이 동일함을 의미한다.

정규화된 출력이 1.0에 가까운 구간을 살펴보면, 약한 불안정 레짐의 빈도율 그래프만이 뾰족한 형태를 보이며, 가장 높은 출현 빈도를 보인다. 정규화된 출력이 1.0에서 멀어지면서(증가 또는 감소), 약한 불안정 레짐의 빈도율은 빠르게 감소한다. 반면, 안정과 강한 불안정 레짐의 정규화된 출력은 1.0에 가까운 빈도가 가장 낮으며, 각각 약 0.85과 약 0.55 부근에서 그 출현 빈도가 높음을 알 수 있다. 이에 따라 이들 레짐에서 풍력터빈 간의 출력 편차가 가장 크게 나타날 것으로 예상되며, 최종적으로 1.0에 가까운 정규화된 출력의 빈도율은 약한 불안정, 중간 불안정, 중립 및 안정(또는 강한 불안정) 레짐 순서로 높게 나타난다.

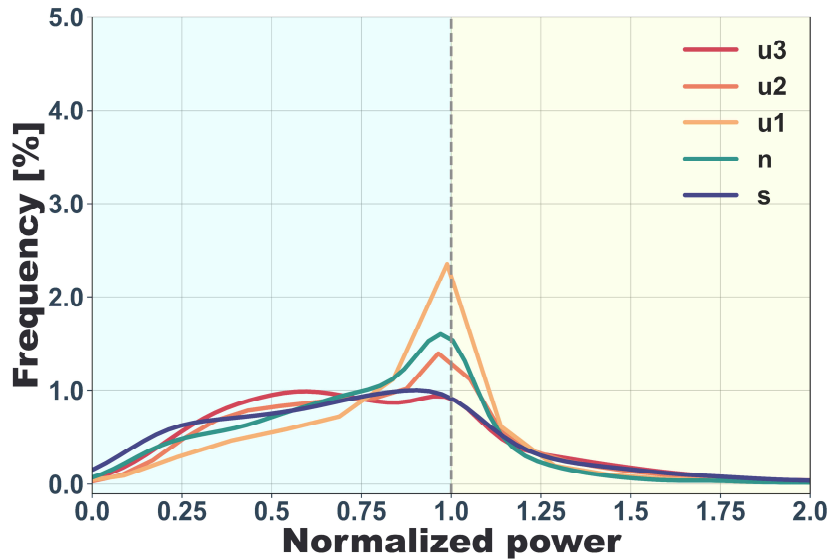


Fig. 4.12 Probability distribution of the normalized power according to the classified atmospheric regimes. The 10-min averaged measurements were used, and the normalized power is expressed in the range 0.0–2.0. Dotted lines indicate a normalized power of 1.0; blue and yellow shaded areas indicate the decrease and increase of the normalized power, respectively.

Fig. 4.13은 대기안정도 레짐별 개별 풍력터빈의 정규화된 출력(a) 및 Mann-Whitney U Test를 이용한 정규화된 출력의 통계검정 결과(b)를 나타낸다.

Fig. 4.13a에서 y축의 풍력터빈 순서는 “Total” 컬럼의 정규화된 출력을 내림차순으로 정렬한 것이다. 전반적으로 불안정 레짐에서 풍력터빈 간의 정규화된 출력의 차이는 낮은 수준을 보이며, 그 범위는 강한 불안정, 중간 불안정 및 약한 불안정 레짐으로 각 1.00~0.62, 1.00~0.64 및 1.00~0.74를 보인다. 특히, 약한 불안정 레짐에서 풍력터빈들의 출력 차이는 30% 미만으로 가장 낮은 변동성을 보인다. 반면, 중립과 안정 레짐일 때, 개별 풍력터빈은 높은 수준의 정규화된 출력의 차이를 보이며, 그 범위는 각각 1.00~0.70 및 1.00~0.54이다. 안정 레짐에서 풍력터빈들의 출력 차이는 약 55%까지 나타나며, 가장 높은 변동성을 보인다. 이를 통해 약한 불안정에서 강한 불안정 또는 안정 레짐으로 성층화되면, 풍력터빈들 사이의 출력 차이가 증가함을 알 수 있다. 또한, DBWF에서는 약한 불안정 레짐으로 성층화되었을 때, 풍력터빈들이 가장 우수한 출력성능이 나타날 것으로



판단된다.

Fig. 4.13b를 살펴보면, 전반적으로 약한 불안정 레짐과 기타 레짐 사이에서 보이는 정규화된 출력 차이는 통계적으로 유의미한 차이(남색)임을 알 수 있다. 그리고, 부분적으로 나타나는 낮은 유의성(빨간색)은 중립 레짐에서 보다 높게 관찰된다. 이러한 결과가 나타나는 이유는 이전의 분석 결과를 통해 그 원인을 파악할 수 있다. 약한 불안정과 중립 레짐은 강한 수준의  $\varepsilon$  출현 빈도가 높았다(Fig. 4.7). 또한, 고품속으로 진행되면서 두 레짐은 유사한 수준의  $\varepsilon$ 이 나타났다(Fig. 4.8). 이러한 점들은 중립상태가 타 레짐에 비해 약한 불안정에 가장 유사한 특성의 바람장이 나타날 가능성이 높음을 시사한다. 이에 따라 중립상태에서 상대적으로 낮은 유의성이 좀 더 관찰되는 것으로 판단된다.

이외에 또 하나의 주목할 만한 점은 풍력터빈의 위치이다. 몇몇 풍력터빈들은 서로 근접한 곳에 위치함에도 불구하고, 정규화된 출력에서는 큰 차이를 보이는 점이다. 대표적으로 6번과 5번 풍력터빈의 경우, 이격 거리가 가까움에도 정규화된 출력의 평균값은 각각 0.94와 0.82를 보인다(Total column). 이와 같은 차이를 보이는 이유는 풍향과 관련이 있다. 분석 자료에서 주 풍향(북서풍)의 비율은 63%로 가장 높은 비율을 차지한다. 주 풍향을 기준으로 인근 풍력터빈과 기타 지형 조건에 영향을 받지 않은 자유 유동이 풍력터빈 6번으로 유입된다. 반면에 6번 풍력터빈의 후류와 풍상측에 위치한 다수 풍력터빈의 중첩 후류로 인해 풍속 저감된 바람장이 5번 풍력터빈으로 유입된다. 이러한 원인으로 근접한 거리에 위치한 풍력터빈들 사이에도 출력은 상당한 차이가 나타날 수 있다.

대기안정도는 유동장의 시어와 난류 상태에 영향을 준다[103]. 또한, 대기안정도는 열적 상태가 고려되기 때문에 지표층 근처 난류의 수직방향 흐름이 반영되며, 난류 흐름의 연직 흐름은 주류방향 보다 후류 굽이침과 후류 회복에 더욱 중요한 역할을 한다[104,105]. 이러한 점들을 고려하였을 때, 레짐에 따라 난류 혼합과 풍력터빈에서 유발된 풍속 저감의 정도는 다를 수밖에 없다. 이는 운영 중인 풍력터빈들의 출력성능에 영향을 미쳐, 레짐에 따라 출력의 유의미한 차이를 나타내는 원인으로 판단된다.



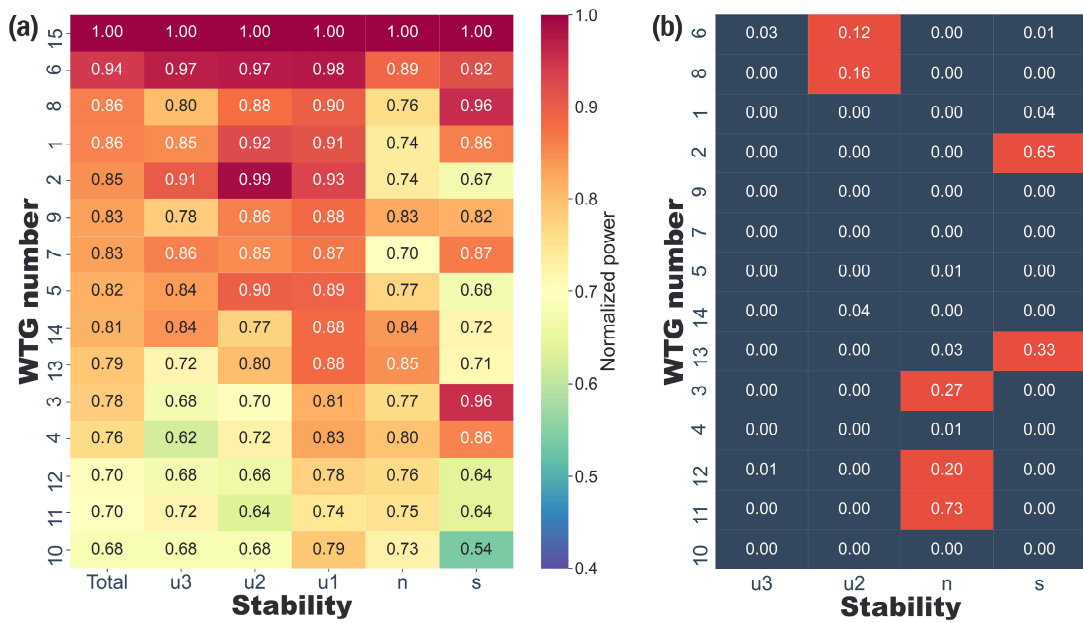


Fig. 4.13 Heatmap: (a) normalized power in individual WTGs by atmospheric stability regime and (b) statistical test of the difference in the normalized power. In (a), the WTGs on the y-axis are in descending order of the average value of normalized power (“Total” column) for individual WTGs. (b) Statistical test results for the differences in the normalized power between the slightly unstable regime and other atmospheric regimes. The “Total” column and No 15. WTGs were excluded. Each cell is marked in dark blue or red, depending on the existence or absence of significant differences in the normalized power ( $p < 0.05$ ).

Fig. 4.14는 3가지 레짐별 15기 풍력터빈의 평균 출력 곡선을 나타낸다. 3가지 레짐은 출력 차이가 가장 작은 약한 불안정, 가장 큰 안정 그리고 중립 레짐이다. 출력 곡선은 약한 불안정, 중립 및 안정 레짐 순서로 우수한 출력을 보인다. 풍력터빈의 시동풍속에서 약 6.5m/s까지는 레짐에 따른 출력 곡선의 유의미한 차이를 파악하기 어렵지만, 7m/s 이상의 풍속부터는 차이를 확인할 수 있다. 특히, 출력 차이는 8.5m/s에서 약한 불안정과 안정 레짐 사이에 271kW의 극대값을 보인다. 2차 최대값은 10.5m/s에서 중립과 약한 불안정 레짐 사이에 265kW를 보인다.

전반적으로 레짐별 출력 곡선은 풍속의 3차 곡선에 단순 비례로 증대되는 형태를 보이지만, 0.5m/s의 동일 풍속 구간이라도 레짐에 따른 출력 곡선의 차이는 나타난다. 안정 레짐이 기타 레짐 보다 출력 곡선의 변동성이 크게 나타난다. 레짐별 출력 곡선의 차이는 약 15m/s까지 유효하며, 이 이상의 풍속 구간에서는

약한 불안정과 중립 사이의 출력 곡선 차이가 확인되지 않는다.

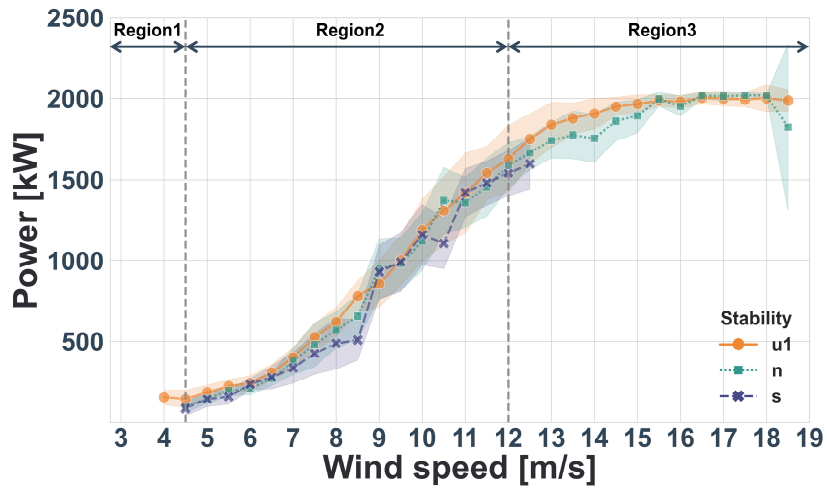


Fig. 4.14 Mean power curve for each regime using power data for all WTGs. The shaded area shows the standard deviation of the power curves for the entire WTGs using the 5–95% percentile data for the turbulence dissipation rate with respect to the atmospheric stability regimes. To analyze the AEP, the power curve portion of 4.5–12m/s in Region 2 was used for the analyses, as discussed in Section 4.2.5.

Fig. 4.15는 대기안정도 레짐별 AEP의 상대 오차를 나타낸다. AEP 산정을 위해 Fig. 4.14의 레짐별 15기 풍력터빈의 출력 곡선과 레일리 분포의 풍속 확률 밀도를 이용하였다. 레일리 분포의 입력값인 연평균풍속은 4~12m/s를 사용하였고, 중립 레짐을 기준으로 기타 레짐과의 AEP 차이를 산출하여 상대 차이를 표현하였다.

AEP 상대 차이 분석 결과, 전반적으로 약한 불안정 레짐이 높은 AEP를 보인다. DBWF의 연평균풍속인 6.02m/s에서 중립상태와 약 7.0%의 AEP 차이를 보이고, 이때 95% 신뢰구간은 2.8~11.2%의 AEP 상대 차이 범위를 보인다. 연평균풍속이 9m/s를 초과하면서부터 중립 레짐과 약 5% 미만의 AEP 차이를 보인다.

안정 레짐은 전체적으로 낮은 AEP를 보인다. 연구 사이트의 연평균풍속에서 중립 레짐과의 AEP 차이는 약 -5.5%를 보이고, 95% 신뢰구간에서는 -7.7 ~ -3.4%의 AEP 상대 차이 범위를 보인다. 연평균풍속이 7m/s를 초과하면서 중립 레짐과 약 5% 미만의 AEP 차이를 보인다.

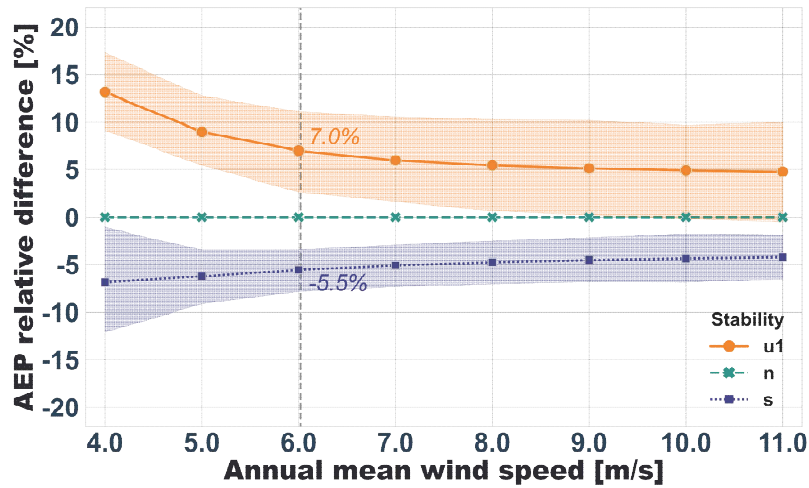


Fig. 4.15 Relative difference in the annual energy production (AEP) of the wind farm according to the atmospheric regimes. The relative difference rate indicates the difference between the neutral atmospheric regime and other regimes. The 5–95% percentile data for the turbulence dissipation rate for each atmospheric stability regime were used. The shaded area indicates a 95% confidence interval, and the gray dotted line indicates the annual mean wind speed at the study site (6.02m/s).

전반적으로 레짐 사이의 AEP 차이는 연평균풍속의 증가와 함께 감소 추세를 보인다. 이외에도 강한 불안정과 중간 불안정 레짐의 AEP 상대 차이는 출력 편차의 변동성이 가장 큰 안정 레짐과 가장 작은 약한 불안정 레짐 사이에 분포할 것으로 예상된다. DBWF와 유사한 조건과 규모의 육상 풍력 발전단지에서는 대기안정도의 레짐에 따라 중립 대기 대비 약 5~7%의 AEP 차이가 발생할 것으로 추정된다. 이러한 결과는 대기안정도 레짐과 이때  $\epsilon$ 의 정량적 특성을 AEP 예측기법에 통합하거나 보완할 필요가 있음을 뒷받침하는 강력한 근거로 볼 수 있다.

## 4.2 에너지 생산량 예측 모델 정확도 분석

### 4.2.1 기계학습 알고리즘의 예측 성능

Fig. 4.16은 일주기 변화에 따른 모델별 정규화된 출력을 나타낸다. 이 분석은 일주기에서 ML 알고리즘들의 기본적인 시뮬레이션 능력을 확인하는 것이 목적이다. 따라서 자료를 트레이닝 자료와 테스트 자료로 분리하지 않고, 가용 데이

터(10분 평균 자료)를 전부 활용하여 모델의 예측 성능을 확인하였다.

입력 피쳐1을 사용했을 때 정규화된 출력을 살펴보면(Fig. 4.16a), 일변화 동안 모델들의 예측값은 실제값과 유사한 패턴을 보인다. 예측값과 실측값 사이의 상대 오차율은 RF1, LGBM1, ANN1 및 SVM1에 따라 각각 0.9, 1.2, 1.5 및 3.2%를 보인다. 트리 기반의 앙상블 학습 알고리즘인 RF1과 LGBM1이 우수한 성능을 보이는 반면, SVM1은 일주기에 전반적인 과소평가 경향을 보인다. SVM1의 예측값과 실측값 사이의 차이는 일출 시각인 6시를 기점으로 증가하고, 한낮인 13시에 극대값(SVM1: 6.8%)을 보이며, 일몰 시각인 18시 이후에 감소 경향을 나타낸다. 기타 모델에서도 정도의 차이는 있을 뿐, 일주기 동안 유사한 경향을 보인다.

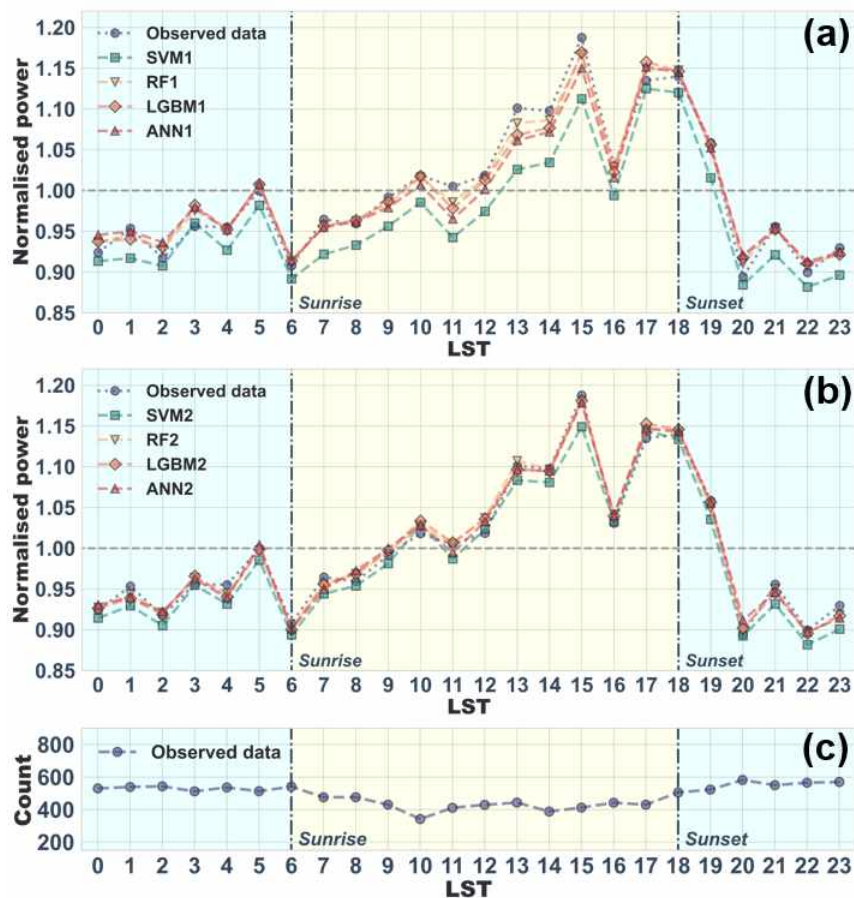


Fig. 4.16 Normalised power by model according to diurnal cycle. (a) and (b) use meteorological factors of input features 1 and input features 2, respectively (see Figure 13).

Predicted values of each model were normalized with actual values for sum of power from 15 wind turbines. (c) number of data with 340-580 10-min average data used per hour.

입력 피처2를 사용했을 때 정규화된 출력을 살펴보면(Fig. 4.16b), 일변화 동안 모델들의 예측값과 실제값 사이의 상대 오차율은 RF2, LGBM2, ANN2 및 SVM2에 따라 각각 0.7, 0.8, 0.9 및 1.5%를 보인다. 상대 오차율은 입력 피처2가 1보다 작게 나타난다. 특히, 입력 피처1을 사용하였을 때 주간에 나타나는 실측값과의 뚜렷한 차이는 입력 피처 2를 사용하였을 때 상당히 감소함을 알 수 있다. 입력 피처2의 난류성분은 주간에 나타나는 예측 오차를 효과적으로 감소시키는 것으로 나타난다. 난류성분 사용에 따른 오차 감소의 이점은 에너지 생산량 추정의 개선으로 이어질 수 있음을 시사한다.

Fig. 4.17은 교차 검증의 결과로서, 입력 피처와 ML 알고리즘에 따른 풍력 발전단지 에너지 생산량 예측의 루트 평균제곱오차 (RMSE)를 나타낸다. RMSE의 감소는 예측 정확도의 개선을 의미하며, 전체적으로 입력 피처2가 입력 피처1에 비해 낮은 RMSE를 보인다. 10분 평균 출력예측의 경우(Fig. 4.17a), RMSE의 감소율은 ML 알고리즘에 따라 약 3.6 9.7% 수준이다. 평균 RMSE는 LGBM1과 SVM1에서 각각 1,820과 2,423으로 가장 낮은 값과 높은 값을 보인다. 1일 발전량 예측의 경우(Fig. 4.17b), RMSE의 감소율은 ML 알고리즘에 따라 약 4.5 6.2%를 보인다. 입력 피처2의 RMSE(파란색)는 RF2, LGBM2 및 ANN2에 따라 각각 60,136, 60,661 및 62,087을 보이며, SVM2와는 상당한 차이를 보인다. 전반적으로 트리와 신경망 기반 알고리즘이 우수한 예측 성능을 보이고, 가장 뛰어난 성능은 LGBM에서 나타났다.

해당 결과는 ML 알고리즘을 이용하여 풍력터빈의 출력 또는 풍력 발전단지의 발전량을 예측할 경우, 난류 관련 매개변수를 입력 피처로 사용한다면, 예측 정확도를 향상시킬 수 있음을 뒷받침하는 근거로 볼 수 있다.

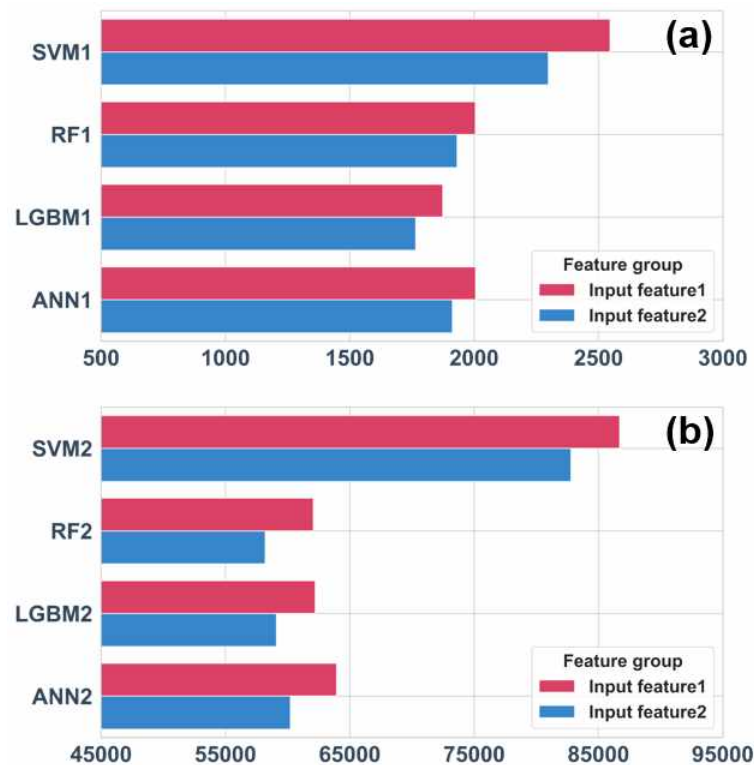


Fig. 4.17 RMSE of 10-min average power and daily energy production prediction of wind farm according to input feature group and machine learning model: (a) 11,688 10-min data sets and K-fold (K = 10, 80%-20% train-test split) CV were used. (b) 163 one-day data and Leave-One-Out CV were used. See Table 4 and Figure 13 for meteorological factor groups of input features 1 and 2.

#### 4.2.2 기상요인 예측 기여도 비교 분석

Fig. 4.18에서는 Fig. 4.17에서 가장 우수한 예측 정확도를 보인 LGBM을 대상으로, XAI 기법의 하나인 SHAP 알고리즘을 이용하여 각 입력 피처의 예측 영향력을 분석하였다. 이 분석은 데이터 세트 내의 모든 인스턴스를 대상으로 SHAP 값 및 특성값의 크기를 표현한다. x축의 SHAP 값을 절대값으로 보았을 때, 그 크기가 클수록 예측값(출력 또는 발전량) 결정에 입력 피처의 기여도가 크다는 것을 나타낸다. 이때, SHAP 값이 음수는 예측값이 작아지는데 영향을 미쳤고, 양수는 예측값이 커지는데 영향이 미쳤음을 의미한다. y축의 피처 순서는 SHAP 값을 기반으로 예측 기여도가 높은 순서로 정렬하였다. 특성값의 빨간색과 파란색은 이에 해당하는 기상요인의 규모가 높고 낮음을 나타낸다.

전체 기상요인 중에서 풍속은 SHAP 값의 가장 큰 분산을 보인다. 풍속의 SH



AP 값 분포는 10분 평균 출력예측과 1일 발전량 예측에 따라 각각 -12,014~19,123와 -125,091~260,667을 보인다. 또한, 풍속의 특성값이 높고 낮음은 고풍속과 저풍속을 의미한다. 고풍속일 때는 SHAP 값이 양수로 예측값을 증가시키고 저풍속일 때는 SHAP 값이 음수로 예측값을 감소시키는데 기여하였다. 에너지 생산량 예측에서 이러한 패턴은 명확하며 풍속은 가장 강력한 역할을 하는 피처임을 확인할 수 있다.

Fig. 4.18a를 살펴보면, 풍속 이외에 풍향, 기온, 압력, 습도 및 WSE 순서로 SHAP 값의 높은 분산 수준을 보인다. 특히, 풍향(-3,337~11,250)과 기온(-8,736~1,591)의 SHAP 값 분산이 높다. 또한, 특성값의 강도에 따라 SHAP 값의 음·양구분이 뚜렷하다. 이 중에서 기온의 경우, 저온일 때는 출력의 증가를 고온일 때는 출력의 감소에 기여하였다. 기온은 계절성이 반영된 입력 피처이다. 겨울철에는 DBWF로 시베리아 고기압에 의한 계절풍이 유입되는데, 이 계절풍은 낮은 온도와 고풍속의 특성을 보인다. 여름철에는 높은 온도와 저 풍속의 특성을 지닌 남서 계절풍이 풍력 발전단지로 유입된다. 따라서, 에너지 생산량과 온도 사이에 내포된 이 상호작용이 모델 구축과정에 하나의 정보로 학습되어 나타난 결과로 풀이된다.

Fig. 4.18b를 살펴보면, Fig. 4.17a와 마찬가지로 풍향과 온도는 예측 기여도가 각 3과 4순위로 높게 나타난다. 이 기상요인들을 전·후로 추가로 입력된 성분들이 위치한다. 특히, 풍력터빈의 허브높이 TI인 TI 80m(2순위)와 풍력터빈의 회전면적 하단 부근 매개변수인 TKE 50m(5순위)는 우수한 예측 기여도를 보인다. y축을 기준으로 TKE 50m보다 낮은 순위의 입력 피처들은 몇 가지 특징을 보인다. SHAP 값의 음·양구분이 뚜렷하지 않은 점 또는 0에 가까운 SHAP 값 분포를 보인다는 점이다. 이러한 점들로 인해 해당 피처들의 기여도 차이를 명확히 확인하기가 어렵다. 다만, 기존 연구에 주로 사용되던 입력 피처들(습도, 압력 및 WSE)과 유사하거나 그 이상의 기여도를 보이는 난류 특성값들(eps 50m, eps 75m, TKE 75m)이 있음을 확인할 수 있다.

Fig. 4.18c를 살펴보면, 10분 평균 출력 예측(Fig. 4.17a)과 비교하였을 때, 풍향과 기온의 기여도는 여전히 높게 나타난다. 여기서 4순위에 있는 WSE는 풍향과 유사한 분산 수준을 보인다. WSE의 특성값이 높고 낮음은 윈드프로 파일의 수



직 구배가 강하고 약함을 의미하며, 이에 따라 예측값의 감소와 증가에 기여한다. 반면에 습도와 압력은 SHAP 값의 낮은 분산(-9,454~13,752)과 특성값에 따른 SHAP 값의 불명확한 음·양 구분을 보인다. 즉, 예측에 기여하는 수준은 낮으며 그 차이를 구분하기 힘들다.

Fig. 4.18의 흥미로운 점 중의 하나는 10분 자료(왼쪽 행)에서 1일 자료(오른쪽 행)로 샘플링 주기가 보다 긴 자료를 사용하면서, 풍속 대비 기타 요인들의 SHAP 값 분산이 증가한다는 점이다. 특히, Fig. 4.18d에서 난류성분들의 분산 수준이 전반적으로 높아진 것을 확인할 수 있다. 또한, 난류성분 특성값에 따른 SHAP 값의 음·양 구분이 뚜렷하게 나타난다. 이러한 점은 음의 영향력(예측값 감소)과 양의 영향력(예측값 증가)이 지닌 정보의 차별성을 보다 부각시킨다. 입력 피쳐 중 TKE 75m와 eps 75m는 기온보다 높은 기여도를 보이고, TI 40m와 TKE 50m는 풍향보다도 높은 기여도를 보인다. ML 알고리즘의 예측과정에서 난류 특

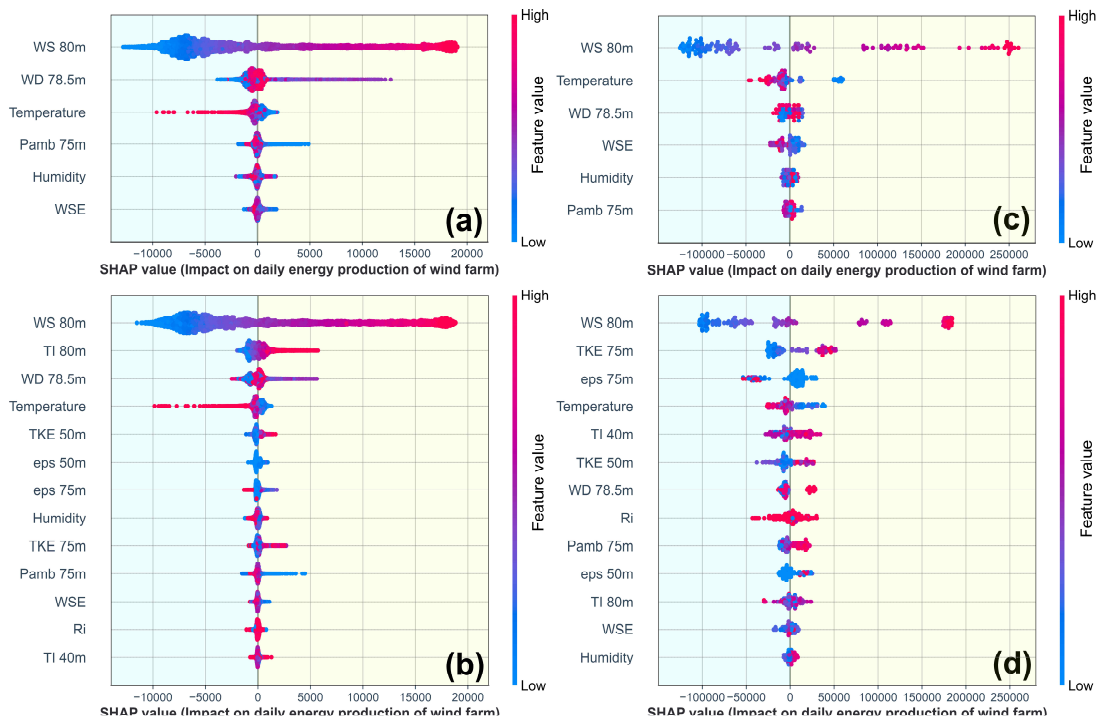


Fig. 4.18 Summary plot of input features using SHAP algorithm. 10-min average power (left column) and daily energy production (right column) prediction results of wind farm using LGBM. Top and bottom rows indicate input features 1 and 2, respectively. The number of 10-min average power and daily energy production data was 11,688 and 163, respectively.

성값들은 차별화된 정보를 제공함으로써, 모델 성능향상에 긍정적 역할을 하는 것으로 판단된다.

풍력 발전단지의 1일 발전량 예측과정에서 풍속 다음으로 높은 기여도를 보인 입력 피쳐는 TKE이다. TKE는 풍속의 수평(u와 v)과 수직(w) 속도 성분의 변동성이다. TKE의 특성값이 높고 낮음은 풍속 변동성의 증가와 감소를 의미하며, 예측값의 증가와 감소로 이어진다. 이는 상당히 명확한 패턴으로 표출되며 유용한 정보를 제공한다. 이를 통해 풍력터빈의 회전 면적 내에서 취득된 TKE는 ML 알고리즘을 이용한 발전량 예측에 있어서 풍속 다음으로 효과적인 기상요인임을 시사한다.

풍속과 기타 기상요인들 사이의 기여도 차이를 보다 정량적으로 비교하고자 Fig. 4.19의 분석을 수행하였다. 이 분석은 Fig. 4.18의 입력 피쳐별 SHAP 값을 절대값으로 평균한 결과이다. 즉, 풍력 발전단지의 에너지 생산량 예측에서 입력 피쳐들의 절대 영향도를 의미한다.

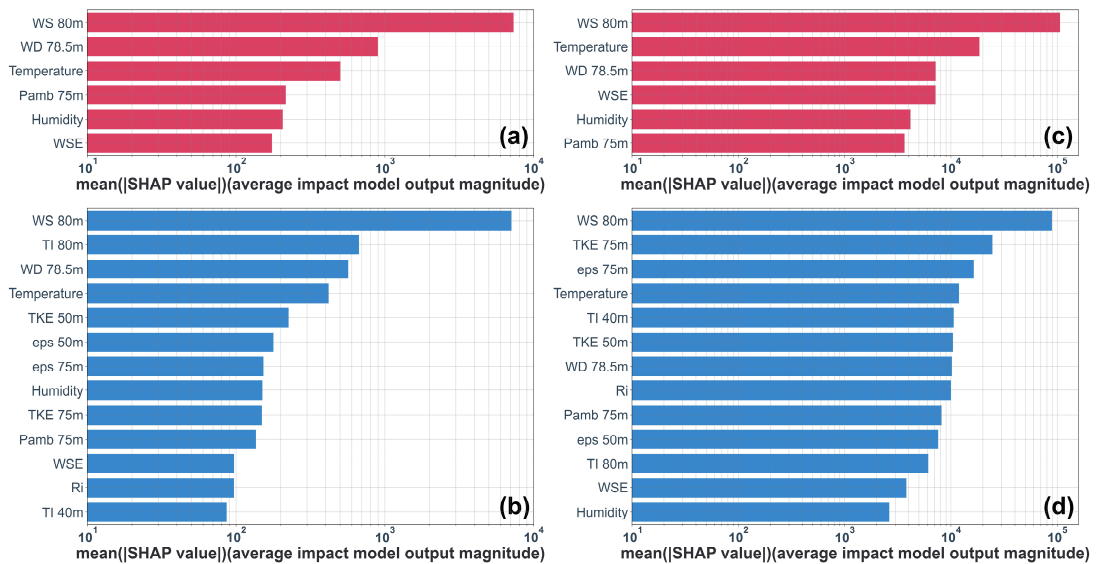


Fig. 4.19 The absolute influence of the SHAP value. The left and right columns are the results of the 10-min average power prediction and the daily energy production prediction of the wind farm, respectively. The top and bottom rows used input features 1 and 2, respectively.

10분 평균 출력예측에서 SHAP 값의 절대 영향도는 풍속이 약  $10^4$ 를 기타 기상요인은 약  $10^2 \sim 10^3$ 을 보이며, 1차수를 초과하는 차이를 보인다(Fig. 4.19a, b). 1일 발전량 예측에서는 풍속이 약  $10^5$ 을 기타 기상요인은 약  $10^4$ 에 근접한 값을 보이며, 약 1차수 수준의 차이를 나타낸다(Fig. 4.19c, d). 1일 발전량 예측에서 풍속 이외의 기상요인들의 영향력 증가는 분명하다. 특히, 입력 피쳐2에서 TKE 75m와 eps 75m의 예측 기여도는 풍속과 1차수 미만의 차이를 보이며 비약적 상승을 확인할 수 있다.

Fig. 4.20과 4.21은 LGBM을 이용한 풍력 발전단지의 1일 발전량 예측에서 SHAP 알고리즘의 Force plot을 이용한 분석 결과물이다. Force plot은 163개의 데이터 중에서 1개의 특정 인스턴스에 대한 SHAP 값을 1차원 평면에 정렬하여 나타낸 것이다. 정렬된 입력 피쳐들은 각각의 기여도가 힘으로 시각화 되어 그래프로 표현된다.

Fig. 4.20의 a와 b를 살펴보면, 풍향은  $294.7^\circ$ 로 자유 유동(Freestream) 영역의 바람장이 DBWF로 유입된 케이스이다. 이때 관측지점은 풍상측에 위치하며, 관측된 풍속은 6.15m/s이다. 예측된 에너지 생산량은 입력 피쳐1(a)과 2(b)에 따라 각각 72,194kWh와 80,006kWh를 보인다. 실제 에너지 생산량인 82,662kWh가 비교했을 때, 각각 -12.7%와 -3.2%로 과소평가를 보인다. 하지만, 입력 피쳐 2는 1에 비해 개선된 예측 정확도를 보인다.

Fig. 4.21의 a와 b를 살펴보면, 풍향은  $193.1^\circ$ 로 후류(Downstream) 영역의 바람장이 DBWF로 유입된 케이스이다. 이때 관측지점인 기상탑은 풍 하측에 위치하며, 관측된 풍속은 6.12m/s이다. 예측된 에너지 생산량은 입력 피쳐1(a)과 2(b)에 따라 각각 87,874kWh와 140,654kWh를 보인다. 실제 에너지 생산량인 145,951kWh가 비교했을 때, 각각 -39.8%와 -3.6%로 과소평가를 보인다. 입력 피쳐 2는 1보다 상당히 개선된 예측 정확도를 보인다.

해당 인스턴스의 난류성분인 TI 40m, Ri 및 TKE 75m가 보인 정량적 수치는 에너지 생산량을 높이 밀어 올리는 힘(red)으로 작용하였다. 반면 eps 50m, TI 80m와 TKE 50m의 값은 에너지 생산량을 낮게 끌어내리는 힘(blue)으로 작용하였다. 상반된 두 힘의 상쇄 작용은 난류성분이 활용된 입력 피쳐2에서 보다 적극

적으로 나타난다. 이를 통해 산출된 예측값은 미묘한 균형점을 보이며 실제값에 보다 근사한 형태를 취한다.

입력 피처 2에 추가된 난류 특성값들은 자유 유동 영역과 후류 영역 케이스 모두에서 예측값을 향상시키는 역할을 수행하였다. 특히, 풍력터빈의 후류로 인해 왜곡된 유동이 관측지점으로 유입되는 후류 영역 케이스에서 예측 정확도의 상당한 개선을 확인할 수 있었다. 이는 비록 후류 효과가 반영된 난류성분 자료라 할지라도 이를 활용하는 것이 예측에 긍정적 영향력을 미칠 수 있음을 시사한다. 또한, 이 분석 결과는 에너지 생산량 예측 메커니즘의 효과적인 개선을 위해, ML 알고리즘에 새롭게 투사된 피처의 입력흐름으로부터 의미를 추출하고 정보를 감지하는 일련의 학습 현상에 한 단면을 제시한다.

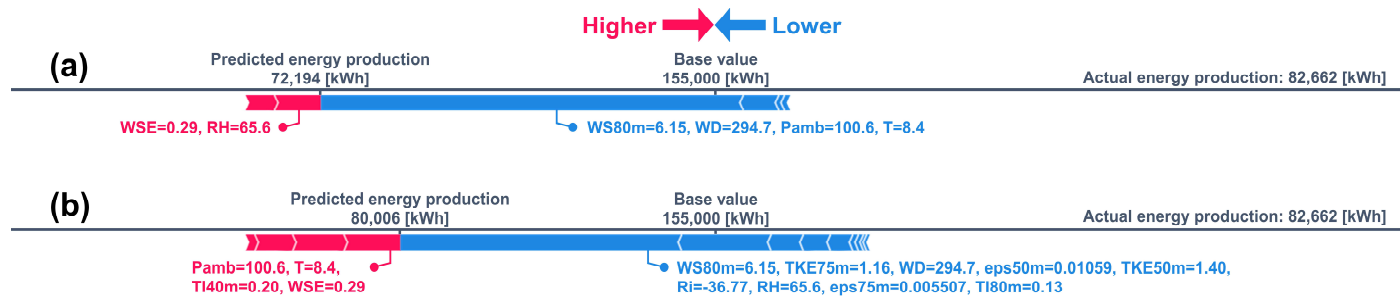


Fig. 4.20 Force plot of the 148th instance (freestream case with wind direction of  $294.7^\circ$ , corresponding to prevailing wind direction) using SHAP algorithm. (a) and (b) used input features 1 and 2, respectively. Daily energy production data were used. The red- and blue-striped arrows indicate influence of features increasing the predicted value and that of features decreasing the predicted value, respectively. The size of arrow indicates scale of feature influence, and base value indicates average value of model for training dataset. WS: wind speed [m/s]; WD: wind direction [ $^\circ$ ]; WSE: wind shear exponential; TI: turbulence intensity; TKE: turbulent kinetic energy [ $\text{m}^2/\text{s}^2$ ]; Ri: Richardson number; Pamb: ambient pressure [kPa]; eps: turbulent dissipation rate [ $\text{m}^2/\text{s}^3$ ]; T: temperature [ $^\circ\text{C}$ ]; RH: relative humidity [%].

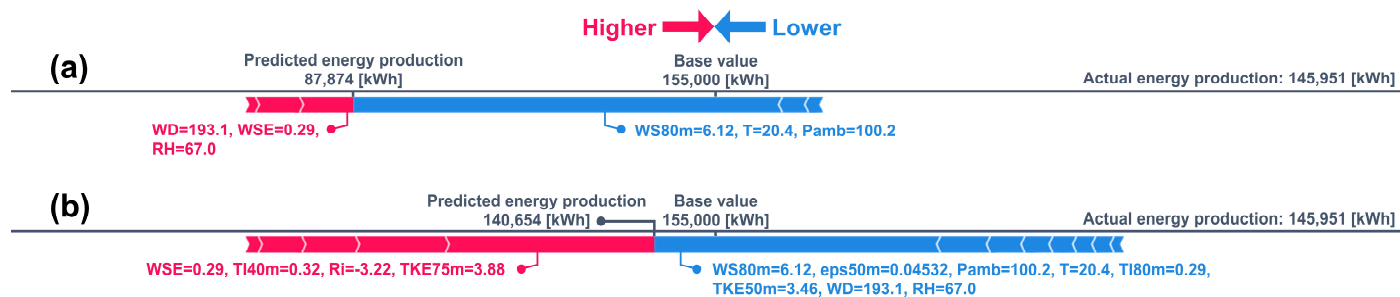


Fig. 4.21 Force plot of 156th instance (downstream case with wind direction of  $193.1^\circ$ ) using SHAP algorithm. (a) and (b) used input features 1 and 2, respectively. Daily energy production data were used. Remaining information is consistent with that presented in Figure 35.

4.2.2 절에서 추가 적으로 살펴볼 만한 점은 3가지로 ML을 이용한 풍력 발전 단지 에너지 생산량 추정에 있어 TKE의 중요한 이유와 이에 반해, 대기안정도의 예측 기여도가 낮은 이유 및 기여도 분석에 사용된 SHAP 알고리즘의 활용 가능성이다. 보다 상세한 논의내용 아래와 같다.

#### 1) 풍력 발전단지 에너지 생산량 추정에 있어 난류운동에너지의 중요성

문헌에 따르면, 기계학습을 이용한 풍력발전 에너지 생산량 예측 연구에서 대부분 입력 피처로 대기안정도와 난류 특성값이 고려되지 않는다[49 - 51,106]. 주로 풍속, 풍향, 온도, 습도 및 압력을 사용할 뿐, 극히 소수의 연구에서만 풍속 분산(wind speed variance), TKE 및 대기안정도 등이 사용된다[39,48]. 하지만, 풍력터빈의 운전 특성을 고려한다면, 에너지 생산량과 난류는 매우 밀접한 연관성이 있음을 알 수 있다. 풍력터빈은 블레이드의 회전 거동을 통해 회전 면적으로 유입되는 바람에서 운동량을 추출한다. 이때 풍력터빈의 풍하측으로 소용돌이와 무작위성 난류가 발생한다[22]. 또한, 운동에너지의 감소를 야기 시킨다[107]. 즉, 후류로 인해 전·후방 풍력터빈의 출력 차이가 유발된다. 보고된 바에 따르면, 후방 풍력터빈에서 약 10~20% 수준의 출력 손실이 나타난다[23]. 이 후류의 회복력에 영향을 미치는 요인이 바로 난류성분이다.

[33]에서는 대기의 성층화가 중립·안정상태일 때보다는 대류 상태일 때, 더욱 빠른 후류 회복과 강한 굽이침(meandering)이 나타난다고 지적한다. 이러한 결과는 대류 경계층에서 나타나는 강한 TI로 인해, 난류 혼합과 유동 유입이 발달하기 때문으로 분석된다. [38]에서는 풍력터빈의 후류 길이와 범위가  $\varepsilon$ 에 강한 의존성을 보인다고 보고한다. 이에 따른 결과로 고풍속에서  $\varepsilon$ 의 규모가  $0.0066\text{m}^2/\text{s}^3$ 에서  $0.013\text{m}^2/\text{s}^3$ 으로 2배 증가할 때, 후류 길이는 680m에서 340m로 반감된다고 제시한다. 또한, [108]연구에서는 3차원 변동성분이 고려된 TKE는 전단응력으로 생성된 난류(수평 방향 변동성)와 열에 의해 생성된 난류(수직 방향 변동성)의 전달과 직접적인 관련이 있음을 지적한다.

상기의 연구 결과들은 난류성분이 풍력터빈의 성능 및 후류 회복의 저해·촉진에 밀접한 관련이 있음을 제시한다. 이를 통해 난류성분이 지닌 물리적 성질은 풍력 발전설비의 성능과 후류 효과에 관여하여 에너지 생산량의 차이로 이어질

수 있음을 알 수 있다. 이러한 점은 풍력 발전단지의 에너지 생산량에 대한 예측 정확도를 향상시키기 위해, ML 알고리즘의 선택뿐만 아니라, 난류성분이 내포한 물리적 성질의 이해 및 해당 성분의 이점이 반영되기 위한 입력 피쳐로서의 활용 또한 매우 중요하다는 것을 시사한다.

## 2) 풍력 발전단지 에너지 생산량 예측에서 대기안정도의 기여도가 낮은 이유

입력 피쳐 중에서 또 하나의 중요한 요인은 바로 대기안정도(예, Obukhov length, Richardson number)이다. 본 연구를 진행하면서 저자들은 대기안정도가 높은 예측 기여도를 보일 것으로 예상하였다. 대기안정도는 풍력터빈의 실질적인 출력성능에 상당한 영향을 미친다는 점[21, 109 - 111]. 본 연구에 사용된  $Ri$ 는 풍력터빈 회전 면적 내의 풍속·온도 차이를 직접 고려하여 계산된 매개변수라는 점. 이와 같은 학술적·이론적 근거를 고려하였을 때, 대기안정도는 높은 예측 기여도를 보일 것으로 예상하였다. 그러나 결과는 예상과 달랐다.

이와 관련하여 [39]의 연구에서는 풍력 발전단지의 에너지 생산량 예측에서 또 다른 대기안정도 매개변수인 Obukhov length (OL)를 다루고 있다. 이 연구에서는 피쳐 중요도를 이용하여 기상요인을 순위화하였고 대기안정도는 가장 낮은 순위를 보였다. 본 연구에서도  $Ri$ 는 12번째(Fig. 4.18b)와 8번째(Fig. 4.18d) 순위로 비교적 낮은 순위에 해당한다. [39]에서는 ML을 이용한 예측에서 대기안정도의 중요도가 낮은 이유에 대해 다음과 같은 3가지 가능성을 제시한다. 첫째, 대기안정도는 “0” 값을 기준으로 불연속적으로 구분되어 모델 구축과정에 이 특성이 제대로 반영되지 못했다는 점. 둘째, 자료를 수집할 때 측정 장비의 불충분한 시간해상도(1s)로 인해 대기안정도 변수가 부정확한 측정이 이루어졌다는 점. 셋째, 몇몇 측정 장비가 오작동했다는 점이다.

본 연구를 위해 약 1년의 측정 캠페인 동안, 3차원 풍속계는 10Hz (0.1 s) 주기로 자료를 수집하였다. 또한, 정확한 측정 성능을 유지하고자 설치업체를 통해 2개월 간격으로 유지 보수 및 보정을 수행하였다. 따라서, 두 번째와 세 번째 가능성은 본 연구에서는 배제하였다. 이를 통해 대기안정도가 실질적으로 에너지 생산량에 영향을 미치고 있음에도 ML 알고리즘에 주요하게 반영되지 못하는 이유는 대기안정도 매개변수가 지닌 불연속성 때문으로 판단된다.



본 연구에 사용된  $R_i$ 는 그 값이 0에 가까울 때, 근 중립상태를 의미한다. 근 중립상태를 기준으로  $R_i$ 의 값이 음수 또는 양수일 때 각각 불안정과 안정 레짐으로 대기가 성층화된다.  $R_i$ 의 값이 음수(양수)로 진전될수록 약한 불안정(안정)에서 강한 불안정(안정)으로 전이된다. 불안정 레짐에서는 난류의 발생과 성장이 촉진되는 반면, 안정 레짐에서는 억제된다. 이와 같은 대기의 물리적 특성 변화는 풍력터빈의 출력과 후류 회복성에 영향을 미쳐 에너지 생산량 차이로 이어진다[33,109,110]. 이 차이는 대기안정도의 분류된 레짐 그리고 그에 따른 강도에 의존성을 보인다. 즉, 음수 또는 양수인지에 따라 그리고 그 규모에 따라 역할과 수준이 상이하게 나타나는 불연속적 특성을 보인다. 이러한 점을 ML 모델 구축 과정에서 온전히 구현하기에는 어려울 것으로 판단된다. 하지만, 전처리(또는 기타방법)를 통해 이 점을 극복한다면, 이에 따른 이득은 모델에 또 하나의 차별화된 정보로써 반영될 수 있다. 이에 대한 보다 자세한 내용은 추가적인 연구가 필요함을 밝힌다.

### 3) XAI의 활용: 피쳐 중요도와 SHAP value

ML은 모델이 의사결정이 가능하도록 알고리즘을 구축하는 과정이다. XAI는 ML 알고리즘의 블랙박스과 같은 의사결정과정을 인간이 이해할 수 있는 수준까지 분해해서 들여다보는 접근방식이다. 이를 통해 모델 개선의 정량적 근거를 마련하고, 연구자로 하여금 합리적 해석 가능성의 토대를 만들 수 있다.

XAI의 활용에 있어 많이 사용되는 기법 중에 하나는 피쳐 중요도(또는 permutation importance)이다[111]. 피쳐 중요도는 특정 피쳐의 값을 치환한 후, 기존 자료 대비 예측 에러 증가를 계산하여 특성의 중요도를 측정하는 방식이다. 특정 피쳐가 예측에 중요하지 않다면 그 피쳐는 모델의 성능에 영향을 주지 않는다. 특정 피쳐 값의 치환으로 모델 에러가 증가할 경우, ML 알고리즘은 이 피쳐의 영향력을 무시하기 때문이다. 즉, ML 모델은 해당 피쳐를 선택해 오차율이 증가하는 것보다 배제하는 것이 낫다고 판단한다. 이러한 장점에도 불구하고 이 접근법은 피쳐들이 서로 의존성을 보일 때, 결과가 왜곡될 수 있다[112]. 피쳐 중요도는 양의 영향력(오차율 감소)만을 고려할 뿐, 음의 영향력(오차율 증가)은 반영되지 않는다. 이에 따라, 어떤 피쳐가 예측값에 부정적인 영향을 미쳐도 이러한 효

과는 배제되며, 이외에 특정 피처가 실제 영향력보다 높게 그 가치가 반영될 수도 있다. 즉, 피처 중요도는 각 피처가 독립적일 때(또는 피처 간 의존성이 낮을 때) 이상적으로 작동한다.

이에 반해, SHAP value는 피처들의 상호 의존성을 고려한다. 각 피처의 스케일을 기반으로 피처 간의 양의 영향력뿐만 아니라 음의 영향력도 계산할 수 있다. 이를 통해 타겟을 결정하는 피처들의 영향력이 어떻게 배분되는지 균형 있게 해석할 수 있다. 이 점은 피처 중요도의 단점을 보완한 대안이 될 수 있다[112]. 또한, SHAP value는 모델 애그노스틱하다. 이는 모델을 설명하기 위해 모델 밖에서 근거를 찾고 모델의 어떠한 특성도 이용하지 않음을 의미한다. 따라서, 모델에 대한 지식 없이도 학습할 수 있기 때문에 모델에 상관없이 적용 가능한 특징이 있다. 예를 들면 딥러닝 모델을 설명하기 위해 트리 설명체를 사용하는 것과 같다. 이는 오리지널 모델에 어떠한 변형도 가하지 않고, 도출된 결과의 설명력을 확보할 수 있다는 장점이 있다. 단, SHAP value는 기본 계산량이 많아 속도가 느리고, 이상치에 약하다는 단점이 있다. 따라서 자료의 세심한 전처리를 통해 이러한 점들을 고려한다면, SHAP value를 통해 다수의 입력 피처가 지닌 기여도의 기본 틀을 추정할 수 있다. SHAP 알고리즘은 ML 기법의 고도화에 있어 실효성 있는 인사이트를 확보하는 강력한 도구가 될 수 있다.

### 4.2.3 에너지 생산량 예측 모델 비교 분석

Table 4.1과 4.2는 6가지 에너지 생산량 예측 모델(Table 3.4 참조)의 정확도 평가 결과를 나타낸다. Table 4.1은 DBWF의 10분 평균 출력의 예측 정확도를 나타내고, Table 4.2은 DBWF의 1일 발전량 예측 정확도를 나타낸다.

10분 평균 출력예측의 경우(Table 4.1), 예측 정확도가 가장 우수한 예측 모델은 6번으로 RMSE와  $R^2$ 는 각각 2,162와 0.870을 보인다. 반면, 성능이 가장 낮은 예측 모델은 1번으로 RMSE와  $R^2$ 는 각각 2,756과 0.745를 보인다. 6번 모델은 하위 예측 모델(대기안정도와 난류 특성값 예측, Fig. 3.2의 ②ML model)이 적용되었으며, 이 하위 모델은 TKE, eps 및 Ri를 예측한다. 1번 모델은 대기안정도와 난류 특성값 예측 모델이 적용되지 않았으며, 출력예측에 TI를 고려하지 않은 모델이다. 여기서 또 하나의 주목할 만한 점은 TI의 활용 유무이다. 모델 1~4번에

서는 입력 피처로 TI를 고려한 모델이 고려하지 않은 모델보다 좀 더 우수한 예측 정확도를 보인다. 특히, 풍력터빈 허브높이의 TI 80m를 활용할 경우, 예측 정확도 개선이 뚜렷했다. 풍력터빈 회전 면적 하단의 TI 40m를 활용한 모델 2번은 모델 1번에 비해 개선되었지만, TI 80m만 고려한 모델 3번이 보다 높은 정확도를 보인다. 모델 5번은 하위 예측 모델에 TI가 포함된 경우이다. 이 모델은 TI의 실측값을 입력 피처로 사용한 모델 3번과 4번에 비해 낮은 예측 정확도를 보인다. 이러한 결과를 바탕으로 살펴보면 풍력 발전단지의 출력예측 모델을 구축할 때, 허브높이 부근 TI의 실측값을 활용하고, 그 외의 난류 특성값은 하위 예측 모델로 계산된 값을 사용한다면, 예측 정확도가 개선될 수 있음을 시사한다.

Table. 4.1 Results of 10-minute average power prediction. 10-minute average of 8,821 data was used. See Table 3.4 for model details.

Predictive model No.	RMSE	MAE	MSE	R <sup>2</sup>
1	2756	2125	7.60E+06	0.745
2	2485	1734	6.17E+06	0.811
3	2257	1635	5.10E+06	0.860
4	2268	1586	5.14E+06	0.852
5*	2411	1689	5.81E+06	0.832
6*	2162	1508	4.68E+06	0.870

\*Models to which sub-prediction models are applied. The sub-prediction model is a model that calculates atmospheric stability and turbulence parameters.

1일 발전량 예측의 경우(Table. 4.2), 예측 정확도가 가장 우수한 모델은 6번으로 RMSE와 R<sup>2</sup>는 각각 53,632와 0.675를 보인다. 반면, 예측 정확도가 가장 낮은 모델은 2번으로 RMSE와 R<sup>2</sup>는 각각 61,362와 0.587을 보인다. 1일 발전량 예측은 10분 평균 출력예측과 유사하게 하위 예측 모델(대기안정도와 난류 특성값 예측, Fig. 3.2의 ②ML model)을 적용하고, 풍력터빈 허브높이의 TI 40m · 80m 실측값을 활용한 모델 6번이 가장 좋은 예측 정확도를 보인다. 이외에 하위 예측 모델이 적용되지 않은 에너지 생산량 예측 모델 2~4번을 살펴보면, 입력 피처로 TI

40m를 사용한 모델 2번과 4번은 단지 입력 피처로 TI 80m만을 고려한 모델 3번에 비해 예측 정확도가 감소하는 것으로 나타난다.

Table. 4.2 Results of daily energy production prediction. 1day average of 180 data was used. See Table 3.4 for model details.

Predictive model No.	RMSE	MAE	MSE	R <sup>2</sup>
1	59593	40617	3.55E+09	0.600
2	61362	42049	3.77E+09	0.587
3	55597	38474	3.09E+09	0.660
4	60380	41036	3.65E+09	0.616
5*	53632	38680	2.88E+09	0.675
6*	53715	36060	2.89E+09	0.683

\*Models to which sub-prediction models are applied. The sub-prediction model is a model that calculates atmospheric stability and turbulence parameters.

대기안정도와 난류 특성값을 추정하는 하위 예측 모델을 활용함으로써 풍력 발전단지 에너지 생산량 예측 모델이 향상됨을 확인하였다. 특히나 10분 평균 출력예측 모델에서는 명확한 정확도 향상을 확인하였다. 1일 발전량 예측 모델의 경우 예측 정확도가 개선되기는 하였지만, 개선의 정도가 작아 보다 많은 자료의 사용 및 정교한 기계학습 알고리즘을 이용한 모델 구축이 요구된다.

최종적으로 입력 피처로 대기안정도와 난류 특성값을 고려할 경우 예측 모델의 정확도는 향상되었으며, 이를 활용한다면 풍력 발전단지 에너지 생산량 예측 모델의 고도화에 기여할 것으로 판단된다.

## V. 결론

### 5.1 요약 및 결론

풍력터빈 에너지 생산량에 영향을 미치는 환경 조건은 크게 지형, 지표 마찰, 장애물, 기상요인 및 인근 풍력터빈의 후류 등으로 분류할 수 있다. 이 중에서 기상요인은 각 사이트 환경에 상당히 의존적이며, 풍력터빈과의 상호작용 속에 터빈의 실질적인 출력성능에 직접적인 영향을 미친다. 기상요인과 풍력터빈 출력 사이에 상관성을 제시하기 위해 다양한 연구가 수행되고 있지만, 주로 다루고 있는 기상요인들은 풍속, 풍향, 온도, 압력, 습도 등으로 제한적이다. 반면, 대기안정도( $Ri$ )와 난류 특성값( $TKE$ ,  $\epsilon$ ,  $TI$ )과 같은 기상요인을 다루는 연구는 부족한 실정이다. 특히, 풍력 발전단지 규모에서의 에너지 생산량과 상기의 기상요인 사이에 보편적 상관성을 제시하는 연구는 매우 불충분하다. 또한, 최근 ML 기반의 예측 모델들이 활용되고 있는 가운데 모델의 의사결정과정에서 기상요인들의 예측 기여도에 대한 기본 틀이 파악되지 않은 채 여전히 블랙박스로 남아있는 실정이다. 따라서, 기상요인과 에너지 생산량 사이의 관계성 및 ML 모델 구축과정에서의 역할에 대해 면밀히 탐구할 필요성이 있음을 시사한다.

본 연구는 우선, DBWF를 대상으로 기상요인의 레짐 변화가 AEP에 미치는 영향성을 정량적 차이로 제시하였다. 다음, ML 알고리즘을 이용하여 에너지 생산량 예측 모델의 구축과정에서 개별 기상요인의 예측 기여도를 규명하였다. 최종적으로 대기안정도와 난류 특성값을 추정하는 하위 예측 모델을 풍력 발전단지 에너지 생산량 예측 모델에 적용하였고, 예측 정확도의 개선 정도와 그 활용 가능성을 평가하였다. 이 연구 결과를 바탕으로 주요 결론은 다음과 같다.

1) 단일 풍력터빈의 경우, 대기의 레짐이 중간 불안정, 고  $TI$  및 고  $TKE$ 일 때 오히려 높은 AEP를 보였다. 풍력터빈의 운전에 있어 난류성분은 부정적 영향을 끼치는 것으로 간주하지만, 이 연구 결과는 완전 발달한 난류 유동 또는 난류의 부재보다는 약화된 난류 및 일정 수준의 난류가 존재하는 환경 조건이 풍력터빈의 발전량 측면에 유리할 수 있음을 시사한다. 풍력 발전단지 규모에서는 대기가

약한 불안정 레짐으로 성층화되었을 때 가장 우수한 AEP가 나타남을 확인하였다. 약한 불안정 레짐에서는 안정 레짐보다 1~2차수 강한  $\epsilon$ 을 보인다. 이  $\epsilon$ 은 에너지 캐스케이드 과정에서 보다 작은 수준의 난류로 분해되는 힘이다.  $\epsilon$ 이 강할 경우 이질적 유동장 사이의 효과적인 혼합을 촉진하는 반면,  $\epsilon$ 이 약할 경우에는 난류 발생 및 성장을 억제한다. 이러한 점을 감안할 때, 두 레짐 사이에는 명백한 물리적 성질의 차이를 내포한다. 이는 DBWF의 성층화된 대기상태의 소산 특성 차이를 의미하며, 본 연구의 정규화된 출력 분석을 통해 WTGs 사이에 필연적으로 발생하는 출력 감소의 수준에 관여함을 확인하였다. 또한, 레짐에 따른 출력 감소의 정도는 통계적으로 유의미한 차이임을 확인하였다. 본 연구 결과인 대기의 레짐에 따른 세분화된 풍력터빈의 출력 차이를 마이크로 사이팅을 위한 엔지니어링 틀에 반영한다면, 보다 정확한 예측이 가능해진다. 향상된 출력예측 기법은 AEP 산출 오차를 감소시켜, 신뢰성 있는 경제성 평가로 이어지는 유의미한 혜택을 제공할 것으로 기대한다.

2) 기상요인 6개를 사용한 입력 피쳐1보다는 13개를 사용한 입력 피쳐2가 풍력 발전단지의 10분 평균 출력 및 1일 발전량 예측에서 보다 우수한 결과를 나타냈다. 특히, SHAP 알고리즘을 이용하여 1일 발전량의 Freestream과 Downstream 케이스를 분석한 결과, 입력 피쳐2를 사용하였을 때, 모두 개선된 예측값을 보이며, 난류 특성값 사용의 이점을 보여주었다. 풍력 발전단지의 에너지 생산량 예측과정에서 난류 특성값의 기여도는 풍속 다음으로 높다. 난류 특성값이 지닌 물리적 성질을 ML 알고리즘의 입력흐름에 정량적으로 반영함으로써, 보다 엄밀한 발전량을 예측하기 위한 접근방식의 경직성을 줄일 수 있다. 즉, 새로운 접근법의 착상, 기존 모델의 개선 및 입력 특성의 선택에 유연성을 확보하는 토대가 될 수 있다. 본 연구 결과인 난류성분의 예측 기여도를 활용하는 행위는 ML 알고리즘 기반 접근방식의 고도화를 위한 강력한 시그널로 판단된다. 이외에 DBWF 에너지 생산량 예측 모델에 대기안정도와 난류 특성값을 추정하는 하위 예측 모델을 추가로 적용할 경우 정확도 개선이 이루어짐을 확인하였다. 특히, 풍력 발전단지의 10분 평균 출력예측에서 상당한 정확도 향상을 보였다. 본 연구에서 추정된 대기안정도와 난류 특성값은 TKE(75m, 50m), eps(75m, 50m), Ri, TI(80m, 40m)이

다. 이 중에서도 풍력터빈의 허브높이에 근접한 매개변수가 예측 기여도가 높은 것으로 분석된다. 따라서 예측 모델 구축 시 우선적으로 허브높이에 근접한 매개변수의 실측값을 활용하고, 실측값을 지속적으로 수집 및 활용할 수 없는 환경에서는 이를 추정하는 하위 예측 모델이 좋은 대안이 될 것으로 판단된다.

본 연구의 결과물은 에너지 생산량 예측 기술의 고도화에 활용될 수 있다. 향상된 예측 기술은 변동성 높은 풍력 에너지원의 효율적 운영을 가능하게 하게 하여, 풍력 발전설비의 안정성과 경제성을 확보할 수 있는 실용성을 제공한다. 또한, 신뢰성 있는 경제성 평가로 이어질 수 있으며, 이는 풍력 발전단지 개발 프로젝트의 위험도를 완화하는데 긍정적 역할을 할 것으로 기대한다.

## 5.2 추후 연구

본 연구에서는 DBWF의 에너지 생산량 예측 모델을 구축하기 위해, 4개 ML 알고리즘의 예측 정확도 비교를 통해 가장 우수한 모델을 선정하였다. 비교 분석을 위해 ML 알고리즘은 일반적 수준의 튜닝을 통해 성능 테스트를 수행하였다. 이 과정에서 성능향상을 위한 보다 정교한 튜닝과 다양한 접근방식을 시도하지 않았다는 한계점을 가지고 있다. 따라서, 접근법의 다양화를 시도할 필요가 있으며, 이 점은 대기안정도와 난류 특성값 예측 모델링에도 해당한다. 또한, 본 연구는 육상 풍력 발전단지만을 대상으로 수행된 결과물이다. 연안과 해상 환경의 풍력 발전단지까지 다루지 못했다는 한계점이 있다. 다수의 풍력 발전단지를 기반으로 보다 넓은 범위의 외부 환경 조건에 대한 비교 분석이 요구된다. 이외에도 에너지 생산량 예측 모델에 사용된 ML 알고리즘의 의사결정과정을 보다 합리적으로 이해하기 위한 분석기법들의 적용과 비교 평가가 요구된다. 상기의 내용을 바탕으로 고려되는 추후 연구는 다음과 같다.

1) 육상·연안·해상 환경의 풍력 발전단지를 대상으로 기상요인의 레짐에 따른 AEP의 차이와 ML 알고리즘 기반 에너지 생산량 예측 모델의 정확도 비교에 관한 연구

2) 타겟 사이트의 지역적 기상현상을 더욱 적절히 고려한 사이트 자동 적응형 매개변수 추정기(automatic adaptive parameter estimation) 개발 및 고도화 연구



3) 풍력 발전단지 에너지 생산량 예측 모델의 개선을 위한, 다양한 XAI 기법의 활용 및 결과물 비교 분석에 관한 연구

## 참고문헌

- [1] Brower M. Wind resource assessment: a practical guide to developing a wind project. John Wiley & Sons; 2012.
- [2] Lee JC, Stuart P, Clifton A, Fields MJ, Perr-Sauer J, Williams L, et al. The Power Curve Working Group's assessment of wind turbine power performance prediction methods. *Wind Energy Science* 2020;5:199-223.
- [3] Landberg L. Meteorology for wind energy: an introduction. John Wiley & Sons; 2015.
- [4] Antoniou I, Pedersen SM, Enevoldsen PB. Wind shear and uncertainties in power curve measurement and wind resources. *Wind Engineering* 2009;33:449-68.
- [5] Dörenkämper M, Tambke J, Steinfeld G, Heinemann D, Kühn M. Atmospheric impacts on power curves of multi-megawatt offshore wind turbines. *Journal of physics: conference series*, vol. 555, IOP Publishing; 2014, p. 012029.
- [6] Motta M, Barthelmie RJ, Vølund P. The influence of non-logarithmic wind speed profiles on potential power output at Danish offshore sites. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology* 2005;8:219-36.
- [7] Van den Berg GP. Wind turbine power and sound in relation to atmospheric stability. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology* 2008;11:151-69.
- [8] Sumner J, Masson C. Influence of atmospheric stability on wind turbine power performance curves 2006.
- [9] Wagenaar JW, Eecen PJ. Dependence of power performance on atmospheric conditions and possible corrections. EWEA, Brussels, Belgium 2011.
- [10] Barthelmie RJ, Churchfield MJ, Moriarty PJ, Lundquist JK, Oxley GS, Hahn S, et al. The role of atmospheric stability/turbulence on wakes at the Egmond aan Zee offshore wind farm. *Journal of Physics: Conference Series*, vol. 625, IOP Publishing; 2015, p. 012002.
- [11] Wharton S, Lundquist JK. Assessing atmospheric stability and its impacts on rotor-disk wind characteristics at an onshore wind farm.

- Wind Energy 2012;15:525-46.
- [12] Rareshide E, Tindal A, Johnson C, Graves A, Simpson E, Bleeg J, et al. Effects of complex wind regimes on turbine performance. Proceedings American Wind Energy Association WINDPOWER Conference (Chicago, IL), 2009.
- [13] Bardal LM, Sætran LR, Wangsness E. Performance test of a 3MW wind turbine-effects of shear and turbulence. Energy Procedia 2015;80:83-91.
- [14] Zhang MH. Wind resource assessment and micro-siting: science and engineering. John Wiley & Sons; 2015.
- [15] Wagner R, Antoniou I, Pedersen SM, Courtney MS, Jørgensen HE. The influence of the wind speed profile on wind turbine performance measurements. Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology 2009;12:348-62.
- [16] Vanderwende BJ, Lundquist JK. The modification of wind turbine performance by statistically distinct atmospheric regimes. Environmental Research Letters 2012;7:034035.
- [17] Choukulkar A, Pichugina Y, Clack CT, Calhoun R, Banta R, Brewer A, et al. A new formulation for rotor equivalent wind speed for wind resource assessment and wind power forecasting. Wind Energy 2016;19:1439-52.
- [18] Wharton S, Lundquist JK. Atmospheric stability affects wind turbine power collection. Environmental Research Letters 2012;7:014005.
- [19] Martin CMS, Lundquist JK, Clifton A, Poulos GS, Schreck SJ. Wind turbine power production and annual energy production depend on atmospheric stability and turbulence. Wind Energy Science 2016;1:221-36.
- [20] Alblas L, Bierbooms W, Veldkamp D. Power output of offshore wind farms in relation to atmospheric stability. Journal of Physics: Conference Series, vol. 555, IOP Publishing; 2014, p. 012004.
- [21] International Electrotechnical Commission. IEC 61400-12-1/ed1. 0 Wind turbines-Part 12-1: power performance measurements of electricity producing wind turbines 2017.
- [22] Lundquist JK, Bariteau L. Dissipation of Turbulence in the Wake of a Wind Turbine. Boundary-Layer Meteorol 2015;154:229-41.

- <https://doi.org/10.1007/s10546-014-9978-3>.
- [23] Barthelmie RJ, Hansen K, Frandsen ST, Rathmann O, Schepers JG, Schlez W, et al. Modelling and measuring flow and wind turbine wakes in large wind farms offshore. *Wind Energy* 2009;12:431-44. <https://doi.org/10.1002/we.348>.
- [24] Sorensen P, Nielsen T. Recalibrating wind turbine wake model parameters—validating the wake model performance for large offshore wind farms. *European Wind Energy Conference and Exhibition, EWEA, 2006*.
- [25] Ghaisas NS, Archer CL. Geometry-Based Models for Studying the Effects of Wind Farm Layout. *J Atmos Oceanic Technol* 2015;33:481-501. <https://doi.org/10.1175/JTECH-D-14-00199.1>.
- [26] Ghaisas NS, Archer CL, Xie S, Wu S, Maguire E. Evaluation of layout and atmospheric stability effects in wind farms using large-eddy simulation. *Wind Energy* 2017;20:1227-40. <https://doi.org/10.1002/we.2091>.
- [27] H K V, W M. *An introduction to computational fluid dynamics: the finite volume method* 2007.
- [28] Vermeer LJ, Sørensen JN, Crespo A. Wind turbine wake aerodynamics. *Progress in Aerospace Sciences* 2003;39:467-510. [https://doi.org/10.1016/S0376-0421\(03\)00078-2](https://doi.org/10.1016/S0376-0421(03)00078-2).
- [29] Réthoré P-E. Wind Turbine Wake in Atmospheric Turbulence 2009:187.
- [30] Porté-Agel F, Bastankhah M, Shamsoddin S. Wind-Turbine and Wind-Farm Flows: A Review. *Boundary Layer Meteorol* 2020;174:1-59. <https://doi.org/10.1007/s10546-019-00473-0>.
- [31] Hancock PE, Pascheke F. Wind-tunnel simulation of the wake of a large wind turbine in a stable boundary layer: Part 2, the wake flow. *Boundary-Layer Meteorology* 2014;151:23-37.
- [32] Machefaux E, Larsen GC, Koblitz T, Troldborg N, Kelly MC, Chougule A, et al. An experimental and numerical study of the atmospheric stability impact on wind turbine wakes. *Wind Energy* 2016;19:1785-805.
- [33] Abkar M, Porté-Agel F. Influence of atmospheric stability on wind-turbine wakes: A large-eddy simulation study. *Physics of Fluids* 2015;27:035104.

- [34] Keck R-E, de Maré M, Churchfield MJ, Lee S, Larsen G, Aagaard Madsen H. On atmospheric stability in the dynamic wake meandering model. *Wind Energy* 2014;17:1689-710.
- [35] Aitken ML, Banta RM, Pichugina YL, Lundquist JK. Quantifying wind turbine wake characteristics from scanning remote sensor data. *Journal of Atmospheric and Oceanic Technology* 2014;31:765-87.
- [36] Frech M. Estimating the turbulent energy dissipation rate in an airport environment. *Boundary-Layer Meteorology* 2007;123:385-93.
- [37] Sarpkaya T. New model for vortex decay in the atmosphere. *Journal of Aircraft* 2000;37:53-61.
- [38] Smalikho IN, Banakh VA, Pichugina YL, Brewer WA, Banta RM, Lundquist JK, et al. Lidar investigation of atmosphere effect on a wind turbine wake. *Journal of Atmospheric and Oceanic Technology* 2013;30:2554-70.
- [39] Optis M, Perr-Sauer J. The importance of atmospheric turbulence and stability in machine-learning models of wind farm power production. *Renewable and Sustainable Energy Reviews* 2019;112:27-41.
- [40] Jung J, Broadwater RP. Current status and future advances for wind speed and power forecasting. *Renewable and Sustainable Energy Reviews* 2014;31:762-77.
- [41] Ding Y. *Data science for wind energy*. CRC Press; 2019.
- [42] Thé J, Yu H. A critical review on the simulations of wind turbine aerodynamics focusing on hybrid RANS-LES methods. *Energy* 2017;138:257-89.
- [43] Sanz Rodrigo J, Chavez Arroyo RA, Moriarty P, Churchfield M, Kosović B, Réthoré P-E, et al. Mesoscale to microscale wind farm flow modeling and evaluation. *Wiley Interdisciplinary Reviews: Energy and Environment* 2017;6:e214.
- [44] Breton S-P, Sumner J, Sørensen JN, Hansen KS, Sarmast S, Ivanell S. A survey of modelling methods for high-fidelity wind farm simulations using large eddy simulation. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 2017;375:20160097.
- [45] Lynch P. *The emergence of numerical weather prediction: Richardson's dream*. Cambridge University Press; 2006.
- [46] Chen N, Qian Z, Nabney IT, Meng X. Wind power forecasts using

- Gaussian processes and numerical weather prediction. *IEEE Transactions on Power Systems* 2013;29:656–65.
- [47] Clifton A, Kilcher L, Lundquist JK, Fleming P. Using machine learning to predict wind turbine power output. *Environmental Research Letters* 2013;8:024009.
- [48] Fischer A, Montuelle L, Mougeot M, Picard D. Statistical learning for wind power: A modeling and stability study towards forecasting. *Wind Energy* 2017;20:2037–47.
- [49] Ouyang T, Zha X, Qin L. A combined multivariate model for wind power prediction. *Energy Conversion and Management* 2017;144:361–73.
- [50] Renani ET, Elias MFM, Rahim NA. Using data-driven approach for wind power prediction: A comparative study. *Energy Conversion and Management* 2016;118:193–203.
- [51] Lahouar A, Slama JBH. Hour-ahead wind power forecast based on random forests. *Renewable Energy* 2017;109:529–41.
- [52] Milligan M, Schwartz M, Wan Y. Statistical wind power forecasting models: Results for US wind farms. National Renewable Energy Lab.(NREL), Golden, CO (United States); 2003.
- [53] Liu H, Tian H-Q, Chen C, Li Y. A hybrid statistical method to predict wind speed and wind power. *Renewable Energy* 2010;35:1857–61.
- [54] Hodge B-M, Zeiler A, Brooks D, Blau G, Pekny J, Reklatis G. Improved wind power forecasting with ARIMA models. *Computer Aided Chemical Engineering*, vol. 29, Elsevier; 2011, p. 1789–93.
- [55] Osório GJ, Matias JCO, Catalão JPS. Short-term wind power forecasting using adaptive neuro-fuzzy inference system combined with evolutionary particle swarm optimization, wavelet transform and mutual information. *Renewable Energy* 2015;75:301–7.
- [56] Yuan X, Chen C, Yuan Y, Huang Y, Tan Q. Short-term wind power prediction based on LSSVM-GSA model. *Energy Conversion and Management* 2015;101:393–401.
- [57] Cui M, Ke D, Gan D, Sun Y. Statistical scenarios forecasting method for wind power ramp events using modified neural networks. *Journal of Modern Power Systems and Clean Energy* 2015;3:371–80.
- [58] Gilpin LH, Bau D, Yuan BZ, Bajwa A, Specter M, Kagal L. Explaining explanations: An overview of interpretability of machine learning.

- 2018 IEEE 5th International Conference on data science and advanced analytics (DSAA), IEEE; 2018, p. 80–9.
- [59] Montavon G, Lapuschkin S, Binder A, Samek W, Müller K-R. Explaining nonlinear classification decisions with deep Taylor decomposition. *Pattern Recognition* 2017;65:211–22.
- [60] Tao S. Deep neural network ensembles. *International Conference on Machine Learning, Optimization, and Data Science*, Springer; 2019, p. 1–12.
- [61] Antonopoulos I, Robu V, Couraud B, Kirli D, Norbu S, Kiprakis A, et al. Artificial intelligence and machine learning approaches to energy demand-side response: A systematic review. *Renewable and Sustainable Energy Reviews* 2020;130:109899. <https://doi.org/10.1016/j.rser.2020.109899>.
- [62] Jeju Island. Wikipedia 2020.
- [63] Bowen AJ, Mortensen NG. WASP prediction errors due to site orography. *Riso National Laboratory* 2004:28–9.
- [64] Wharton S, Lundquist JK. Atmospheric stability impacts on power curves of Tall wind turbines—an Analysis of a West Coast North American wind farm. Lawrence Livermore National Lab.(LLNL), Livermore, CA (United States); 2010.
- [65] Horst TW, Semmer SR, Maclean G. Correction of a non-orthogonal, three-component sonic anemometer for flow distortion by transducer shadowing. *Boundary-Layer Meteorology* 2015;155:371–95.
- [66] Commission IE. IEC 61400-1. *Wind Turbines-Part* 2005;1.
- [67] Mahrt L. Nocturnal boundary-layer regimes. *Boundary-Layer Meteorology* 1998;88:255–78.
- [68] Rodrigo JS, Guillén FB, Arranz PG, Courtney MS, Wagner R, Dupont E. Multi-site testing and evaluation of remote sensing instruments for wind energy applications. *Renewable Energy* 2013;53:200–10.
- [69] Arya PS. *Introduction to micrometeorology*. Elsevier; 2001.
- [70] Clifton A, Schreck S, Scott G, Kelley N, Lundquist JK. Turbine inflow characterization at the national wind technology center. *Journal of Solar Energy Engineering* 2013;135.
- [71] Kolmogorov AN. Dissipation of energy in locally isotropic turbulence. *Akademiia Nauk SSSR Doklady*, vol. 32, 1941, p. 16.
- [72] McCaffrey K, Bianco L, Wilczak JM. Improved observations of



- turbulence dissipation rates from wind profiling radars. *Atmospheric Measurement Techniques* 2017;10:2595–611. <https://doi.org/10.5194/amt-10-2595-2017>.
- [73] Obukhov AM. Some specific features of atmospheric turbulence. *Journal of Geophysical Research (1896–1977)* 1962;67:3011–4. <https://doi.org/10.1029/JZ067i008p03011>.
- [74] Wyngaard JC, Coté OR. The budgets of turbulent kinetic energy and temperature variance in the atmospheric surface layer. *Journal of the Atmospheric Sciences* 1971;28:190–201.
- [75] Fairall CW, Larsen SE. Inertial-dissipation methods and turbulent fluxes at the air-ocean interface. *Boundary-Layer Meteorology* 1986;34:287–301.
- [76] Kolmogorov AN. The local structure of turbulence in incompressible viscous fluid for very large Reynolds numbers. *Cr Acad Sci URSS* 1941;30:301–5.
- [77] Taylor GI. Statistical theory of turbulence. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 1935;151:421–44. <https://doi.org/10.1098/rspa.1935.0158>.
- [78] Rautenberg A, Schön M, zum Berge K, Mauz M, Manz P, Platis A, et al. The Multi-Purpose Airborne Sensor Carrier MASC-3 for Wind and Turbulence Measurements in the Atmospheric Boundary Layer. *Sensors* 2019;19:2292.
- [79] Muñoz-Esparza D, Sharman RD, Lundquist JK. Turbulence dissipation rate in the atmospheric boundary layer: Observations and WRF mesoscale modeling during the XPIA field campaign. *Monthly Weather Review* 2018;146:351–71.
- [80] Sakagami Y, Santos PA, Haas R, Passos JC, Taves FF. Effects of turbulence wind shear wind veer and atmospheric stability on power performance: a case study in Brazil. *EWEA Annual Event* 2015.
- [81] Oh H, Ha K-J, Shim J-S. Analysis for onset of Changma using Jeodo ocean research station data. *Atmosphere* 2014;24:189–96.
- [82] Scikit-learn 1.0 documentation. Imputation of missing values. n.d. <https://scikit-learn.org/stable/modules/impute.html#iterative-imputer>.
- [83] Wagner R, Pedersen TF, Courtney M, Antoniou I, Davoust S, Rivera RL. Power curve measurement with a nacelle mounted lidar. *Wind Energy* 2014;17:1441–53.

- [84] Fleming PA, Scholbrock AK, Jehu A, Davoust S, Osler E, Wright AD, et al. Field-test results using a nacelle-mounted lidar for improving wind turbine power capture by reducing yaw misalignment. *Journal of Physics: Conference Series*, vol. 524, IOP Publishing; 2014, p. 012002.
- [85] Rousseeuw PJ, Croux C. Alternatives to the median absolute deviation. *Journal of the American Statistical Association* 1993;88:1273–83.
- [86] Massey Jr FJ. The Kolmogorov–Smirnov test for goodness of fit. *Journal of the American Statistical Association* 1951;46:68–78.
- [87] Kolmogorov–Smirnov AN, Kolmogorov A, Kolmogorov M. Sulla determinazione empirica di una legge di distribuzione 1933.
- [88] Smirnov N, Smirnov NV. On the estimation of the discrepancy between empirical curves of distribution for two independent samples 1939.
- [89] Mann HB, Whitney DR. On a test of whether one of two random variables is stochastically larger than the other. *The Annals of Mathematical Statistics* 1947:50–60.
- [90] Aizerman MA. Theoretical foundations of the potential function method in pattern recognition learning. *Automation and Remote Control* 1964;25:821–37.
- [91] Boser BE, Guyon IM, Vapnik VN. A training algorithm for optimal margin classifiers. *Proceedings of the fifth annual workshop on Computational learning theory*, 1992, p. 144–52.
- [92] Breiman L. Bagging predictors. *Machine Learning* 1996;24:123–40.
- [93] Breiman L. Random forests. *Machine Learning* 2001;45:5–32.
- [94] LightGBM. Wikipedia 2021.
- [95] Multilayer perceptron. Wikipedia 2020.
- [96] Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection. *Ijcai*, vol. 14, Montreal, Canada; 1995, p. 1137–45.
- [97] Scikit-learn 1.0 documentation. Cross-validation: evaluating estimator performance. n.d. [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.LeaveOneOut.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.LeaveOneOut.html).
- [98] Lundberg S, Lee S-I. A unified approach to interpreting model predictions. *ArXiv Preprint ArXiv:170507874* 2017.
- [99] Shapley LS. A value for n-person games. *Contributions to the Theory*

- of Games 1953;2:307-17.
- [100] Bodini N, Lundquist JK, Newsom RK. Estimation of turbulence dissipation rate and its variability from sonic anemometer and wind Doppler lidar during the XPIA field campaign. *Atmospheric Measurement Techniques* 2018;11.
- [101] Hand MM, Kelley ND, Balas MJ. Identification of wind turbine response to turbulent inflow structures. *ASME/JSME 2003 4th Joint Fluids Summer Engineering Conference, American Society of Mechanical Engineers Digital Collection*; 2003, p. 2557-66.
- [102] Hansen KS, Larsen GC. Characterising turbulence intensity for fatigue load analysis of wind turbines. *Wind Engineering* 2005;29:319-29.
- [103] Porté-Agel F, Bastankhah M, Shamsoddin S. Wind-Turbine and Wind-Farm Flows: A Review. *Boundary-Layer Meteorol* 2020;174:1-59. <https://doi.org/10.1007/s10546-019-00473-0>.
- [104] Cheng W-C, Porté-Agel F. A simple physically-based model for wind-turbine wake growth in a turbulent boundary layer. *Boundary-Layer Meteorology* 2018;169:1-10.
- [105] Larsen GC, Madsen HA, Thomsen K, Larsen TJ. Wake meandering: a pragmatic approach. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology* 2008;11:377-95.
- [106] Yesilbudak M, Sagiroglu S, Colak I. A novel implementation of kNN classifier based on multi-tupled meteorological input data for wind power prediction. *Energy Conversion and Management* 2017;135:434-44. <https://doi.org/10.1016/j.enconman.2016.12.094>.
- [107] Zhang MH. *Wind resource assessment and micro-siting: science and engineering*. John Wiley & Sons; 2015.
- [108] Wharton S, Lundquist JK. Assessing atmospheric stability and its impacts on rotor-disk wind characteristics at an onshore wind farm. *Wind Energy* 2012;15:525-46.
- [109] Kim D-Y, Kim Y-H, Kim B-S. Changes in wind turbine power characteristics and annual energy production due to atmospheric stability, turbulence intensity, and wind shear. *Energy* 2021;214:119051. <https://doi.org/10.1016/j.energy.2020.119051>.
- [110] Martin CMS, Lundquist JK, Clifton A, Poulos GS, Schreck SJ. Wind

turbine power production and annual energy production depend on atmospheric stability and turbulence. Wind Energy Science 2016;1:221-36.

- [111] Model Class Reliance: Variable Importance Measures for any Machine Learning Model Class, from the “Rashomon” Perspective | DeepAI n.d.  
<https://deepai.org/publication/model-class-reliance-variable-importance-measures-for-any-machine-learning-model-class-from-the-rashomon-perspective> (accessed March 26, 2021).
- [112] Molnar C. Interpretable machine learning. Lulu. com; 2020.

## 부 록

### 부록 A. 제주 동북·북촌 풍력발전단지 유효 방위각 분석

Table. A.1 Calculation of the disturbance sector of the meteorological tower due to wakes of nearby wind turbines. The undisturbed sector is  $247^{\circ} \sim 119^{\circ}$ .

Object	$L_n$ [m]	$D_n$ [m]	Angle[ $^{\circ}$ ]	Disturbed sector[ $^{\circ}$ ]	$\Theta$ [ $^{\circ}$ ]
WTG 1	602	86	225	45.0	247.0 ~ 202.0
WTG 2	480	86	200	50.1	225.1 ~ 174.9
WTG 3	664	86	178	43.0	199.5 ~ 156.5
WTG 4	815	86	160	39.2	179.6 ~ 140.4
WTG 5	1231	86	175	33.4	191.7 ~ 158.3
WTG 6	1163	86	188	34.1	205.0 ~ 171.0
WTG 7	1434	86	203	31.7	218.9 ~ 187.1
WTG 8	1451	86	192	31.6	207.8 ~ 176.2
WTG 9	1474	86	181	31.4	196.7 ~ 165.3
WTG 10	1480	86	171	31.4	186.7 ~ 155.3
WTG 11	1248	86	154	33.2	170.6 ~ 137.4
WTG 12	1287	86	138	32.9	154.1 ~ 121.2
WTG 13	709	86	140	41.7	160.8 ~ 119.2
WTG 14	452	86	154	51.6	179.8 ~ 128.2
WTG 15	245	86	184	69.5	218.8 ~ 149.2




Fig. A.1 Disturbed sectors between meteorological towers and individual wind turbines in Dongbok-Bukchon wind farm.

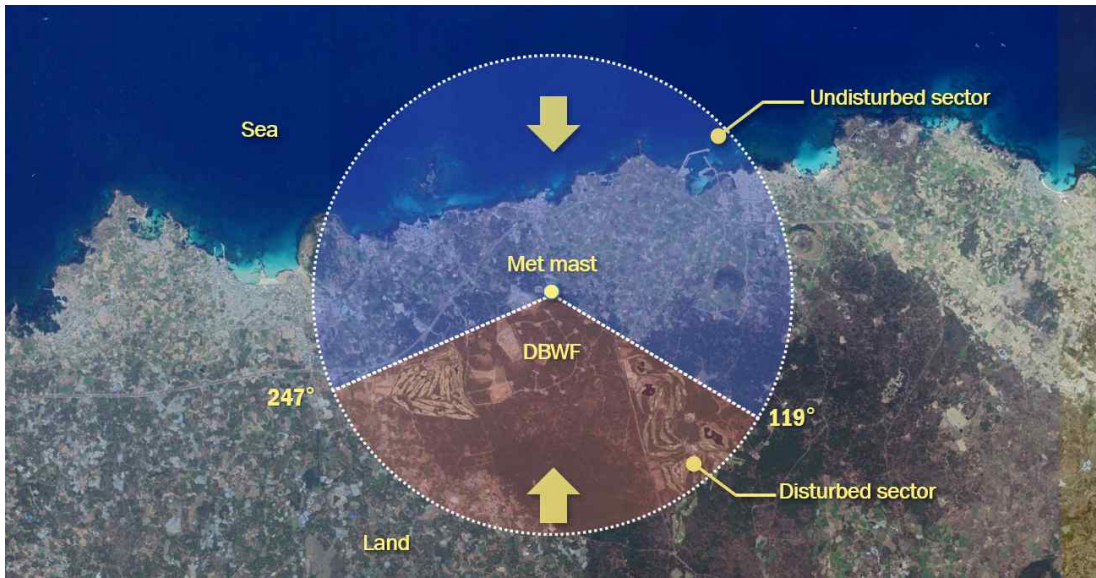


Fig. A.3 Disturbed and undisturbed sectors in Dongbok-Bukchon wind farm.



부록 B. 제주 동북·북촌 풍력발전단지 지형학적 변동성 분석

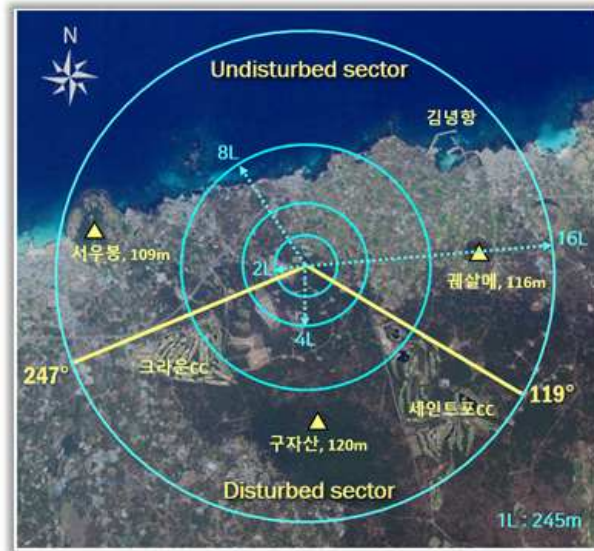


Fig. B.1 Information on topographic profiles for analysis of topographical variations. Analysis was performed on a distance within 16L of the meteorological tower.

Table. B.1 DBWF site requirements: Analysis of topographical variations

Distance	Sector	Maximum slope [%]		Maximum terrain variation from plane	
		Ref.	Result	Ref.	Result
< 2L	360°	< 3	2.51	$< \frac{1}{3}(H-0.5D)$ =12.33	12.28
$\geq 2L$ and $< 4L$	Measurement sector	< 5	1.82	$< \frac{2}{3}(H-0.5D)$ =24.7	2.66
$\geq 2L$ and $< 4L$	Outside measurement sector	< 10	2.92	Not applicable	-
$\geq 4L$ and $< 8L$	Measurement sector	< 10	3.00	$< (H-0.5D)$ =37	5.71
$\geq 8L$ and $< 16L$	Measurement sector	< 10	3.64	Not applicable	-

\*H (hub height) = 80m, D (rotor diameter) = 86m



## 감사의 글

매일 한 장씩 벽돌을 쌓아 올리자는 마음으로 이 길에 들어섰습니다. 조급함을 떨쳐내고 뚜벅뚜벅 나아가다 보니 주변에 동료들과 같이 걷게 되었습니다. 우리에게 아낌없는 격려와 지지를 보내주시는 소중한 분들도 보이기 시작했습니다. 이들과 함께여서 나아갈 수 있었습니다. 참 다행입니다. 그리고 즐거웠습니다. 그분들께 감사의 마음을 전합니다.

박사과정 동안 한 명의 독립된 연구자로서 성장할 수 있게 저의 바탕과 꼴을 잡아주신 김범석 교수님께 진심으로 감사드립니다. 학위논문을 심사해주신 고정남 교수님, 정지현 교수님, 배운혁 교수님, 고진환 교수님께도 감사의 말씀을 드립니다. 심사과정을 통해 보다 나은 결과물을 만들 수 있었고, 연구 필요성과 향후 연구에 대한 고심을 거듭하며 방향성을 찾을 수 있었습니다. 그리고 저를 관련분야로 이끌어주시고 아낌없는 지원을 해주신 허종철 교수님과 양경부 박사님께도 감사 인사를 드립니다.

학위과정 중 문제에 맞닥뜨렸을 때, 같이 고민해주고 끊임없는 대화를 통해 해결책을 탐구해준 신재생에너지 엔지니어링 연구실 그리고 풍력공학 연구실 선·후배들에게 감사드립니다. 연구 과정에서 도움을 주고 든든한 지원군이 되어준 국립기상과학원 팀 동료들에게도 감사드립니다. 이외에 미처 언급하지 못한 풍력공학부 선·후배와 행정실 선생님들에게도 감사드립니다.

4년이라 시간 동안 무한한 지지를 보내준 부모님과 동생에게도 감사의 마음을 전합니다. 그리고 박사과정의 첫발을 내딛게 해주었고, 학위논문을 쓰는 동안 정신적·정서적으로 많은 응원을 보내준 아내에게 깊은 감사를 보냅니다. 마지막으로 박사과정 시작과 함께 태어난 그리고 아빠를 보면 항상 달려와 즐겁게 반겨주는 귀염둥이 라온이에게도 감사의 마음을 전합니다.

2021년 12월 21일  
공과대학 3호관 연구실에서  
김대영