



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

기상수치모델을 이용한 풍황 및
출력변동성을 고려한 풍력발전량 예보

제주대학교 대학원

풍력특성화협동과정

허 수 영

2019년 2월

기상수치모델을 이용한 풍황 및 출력변동성을 고려한 풍력발전량 예보


지도교수 허 종 철


허 수 영


이 논문을 공학 박사학위 논문으로 제출


2018 년 12월


허수영의 공학 박사학위 논문을 인정함

심사위원장 김 병 석 

위 원 고 경 남 

위 원 김 인 현 

위 원 양 정 부 

위 원 허 종 철 

제주대학교 대학원

2018 년 12월

Wind Power Forecasting Considering the Variation
of Power Production and the Wind Resource based
on Numerical Weather Prediction Model

Sooyoung Her
(Supervised by professor Jong-Chul Huh)

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

2018. 12.


This dissertation has been examined and approved.


.....

Dissertation director, Bumsuk Kim, Prof. of Faculty of Wind Energy Engineering, Co-chair


.....

Dissertation director, Kyungnam Ko, Prof. of Faculty of Wind Energy Engineering


.....

Dissertation director, Keon-Hoon Kim, Korea Institute of Energy Research


.....

Dissertation director, Kyoungboo Yang, Prof. of Faculty of Wind Energy Engineering


.....

Dissertation director, Jong-Chul Huh, Prof. of Mechanical Engineering

December. 2018

Faculty of Wind Energy Engineering
GRADUATE SCHOOL
JEJU NATIONAL UNIVERSITY

목 차

List of Figures

List of Tables

Abstract

1. 서 론	1
1.1. 연구배경	1
1.2. 국내외 연구동향	2
1.3. 연구목적	10
2. 실시간 풍력발전량 예보 시스템 개념설계	11
2.1. 기상수치모델	11
2.2. 예보 목적 및 예보 시간	15
2.3. 예보 해상도 및 예보 대상	16
2.4. 예보방법	17
2.5. 예보 시스템 개념설계 프로세스	19
3. WRF 모델을 이용한 예보 시스템 상세설계	27
3.1. WRF configuration	27
3.1.1. WRF 모델 구성 및 설치	27
3.1.2. WRF 모델의 scheme 구성	34
3.1.3. WRF 모델 수행과정	44
3.2. 상세설계 프로세스	45
3.2.1. 하드웨어 구축 및 성능 최적화	46
3.2.2. WRF 모델의 LSM 성능 최적화	50
3.2.3. 예보 시스템 scheduling	56

3.3. 통계모델을 위한 UV method.....	59
3.4. 예보 평가 지표.....	77
4. 실시간 풍력발전량 예보 정확도 평가.....	85
4.1. 연구 대상.....	85
4.2. 풍속 예보 정확도 결과.....	89
4.3. 풍력발전량 예보 정확도 결과.....	92
5. 실시간 풍력발전량 변동성 평가	101
5.1. MCS 방법론.....	102
5.2. 변동성 요소 및 추정.....	106
5.2.1. WRF 모델의 풍속 변동성 평가.....	106
5.2.2. 출력변동 및 공기밀도에 의한 풍력발전량 변동성 평가.....	108
5.3. 풍력발전량 변동성 평가 결과.....	124
6. 결 론.....	129

References

Appendices

List of Figures

Fig. 2-1 The concept map of the numerical weather prediction model.....	12
Fig. 2-2 GSM, LFM, MSM domain.....	13
Fig. 2-3 The conceptual design of a real-time wind power forecasting system.....	23
Fig. 2-4 The process of a wind power forecasting system for real-time grid operation.....	24
Fig. 2-5 The process of a wind power forecasting system for operation in a electricity market.....	24
Fig. 2-6 The process of a wind power forecasting system for the control of wind turbines.....	25
Fig. 2-7 The process of a wind power forecasting system for wind turbine operation planning.....	25
Fig. 3-1 WRF modeling system flow chart.....	28
Fig. 3-2 WRF model domain D01 and D02.....	33
Fig. 3-3 WRF model domain D03 and D04.....	33
Fig. 3-4 Flowchart of the microphysics in the WRF Single-Moment 6-Class scheme.....	34
Fig. 3-5 Decision subjects for running WRF model.....	42
Fig. 3-6 The process of the real-time wind power forecasting system.....	44
Fig. 3-7 Detailed design for real-time wind power forecasting system.....	46
Fig. 3-8 The speed ratio of hardware performance test using three types of parallel computing.....	48
Fig. 3-9 MAE increases over forecasting time.....	50
Fig. 3-10 Surface energy budget of Noah-MP LSM from eq. 2.....	52
Fig. 3-11 Model structural difference between Noah LSM and Noah-MP LSM.....	52
Fig. 3-12 Forecast error of WRF model with Noah LSM and Noah-MP LSM in medium-term.....	54
Fig. 3-13 Forecast error of wind speed in the WRF model with Noah LSM and	

Noah-MP LSM in long-term.	55
Fig. 3-14 Forecast error of temperature in the WRF model with Noah LSM and Noah-MP LSM in long-term.	55
Fig. 3-15 Forecast error of pressure in the WRF model with Noah LSM and Noah-MP LSM in long-term.	56
Fig. 3-16 Scheduling for medium-term wind power forecasting system considering the time required to run WRF model and download GFS data.	58
Fig. 3-17 Final forecasting schedule in medium-term wind power forecasting system.	58
Fig. 3-18 Error of the case of averaged wind direction (a) averaged wind direction in degree, (b) the true value of averaged wind direction, (c) averaged wind direction using u-speed and v-speed.....	60
Fig. 3-19 Error of the case of corrected wind direction (a) the correction to wrong way, (b) the correction of right way, (c) corrected wind direction using u-speed and v-speed.....	60
Fig. 3-20 The processing of applying a statistical model with UV method(a) and without UV method(b).	61
Fig. 3-21 the structure of a neural network using wind speed and wind direction. ·	65
Fig. 3-22 the structure of a neural network using u-speed and v-speed.	65
Fig. 3-23 Measured and predicted wind direction from WRF model.	70
Fig. 3-24 Measured and predicted wind direction from NN(WSWD) model.	71
Fig. 3-25 Measured and predicted wind direction from NN(UV) model.	71
Fig. 3-26 Wind rose from measure data, WRF data, NN(WSWD) data, and NN(UV). 72	
Fig. 3-27 Comparison of wind speed from measured data and WRF data.	73
Fig. 3-28 Comparison of wind speed from measured data and NN(WSWD) data.	73
Fig. 3-29 Comparison of wind speed from measured data and NN(UV) data.	74
Fig. 3-30 Comparison of wind direction from measured data and WRF data.	74
Fig. 3-31 Comparison of wind direction from measured data and NN(WSWD) data. ·	75
Fig. 3-32 Comparison of wind speed from measured data and NN(UV) data.	75
Fig. 3-33 MAE results of predicted power production in long-term wind power	

forecasting.....	77
Fig. 3-34 The example of IOA in best case(a) and worst case(b).....	80
Fig. 3-35 Description of quadrants based on the mean of x, y values in Pearson correlation coefficient.....	82
Fig. 4-1 Summary of Hang-won met.mast.....	87
Fig. 4-2 Comparison of wind speed from measured data and WRF data in medium-term(72h).....	91
Fig. 4-3 Forecasting error of MAE, RMSE for hourly wind speed in medium-term.....	91
Fig. 4-4 Forecasting error of MAE, RMSE for hourly wind speed in long-term.....	92
Fig. 4-5 Forecasting error of MAE, RMSE for hourly power production in medium-term.....	95
Fig. 4-6 Forecasting error of MAE, RMSE for daily power production in long-term.....	95
Fig. 4-7 MAE of pressure and temperature in long-term wind power forecasting.....	97
Fig. 4-8 Pressure data from 1day to 7day.....	98
Fig. 4-9 Pressure data from 8day to 14day.....	98
Fig. 4-10 Temperature data from 1day to 7day.....	99
Fig. 4-11 Temperature data from 8day to 14day.....	99
Fig. 4-12 Air density from 1day to 7day.....	100
Fig. 4-13 Air density from 8day to 14day.....	100
Fig. 5-1 GUM approach and MCS approach in uncertainty estimation.....	103
Fig. 5-2 data set of power production and power curve.....	105
Fig. 5-3 MCS process for the variation of the wind power forecasting.....	105
Fig. 5-4 The RMSE results from data sets collecting from AWS in 2010.....	107
Fig. 5-5 Comparison of power curve uncertainty in pitch-controlled wind turbine from IEC 61400-12-1, Kim and Hyun, NERL report.....	110
Fig. 5-6 The amount of variation for power production in Vestas-V90 3.0MW wind turbine.....	111
Fig. 5-7 Definition of maximum power fluctuation rate under the rated wind speed.....	111
Fig. 5-8 The power curve at maximum and minimum air density in Vestas	

V47-660kW.	114
Fig. 5-9 Summary of the uniform distribution.	114
Fig. 5-10 The pseudo-random data set using MCS in Vestas V47-660kW with variation of air density and wind speed fluctuation.	115
Fig. 5-11 Estimating for the standard deviation of power production.	117
Fig. 5-12 The normal distribution of Present study and Jung approach results in Vestas V90 3.0 MW at 10 m/s wind speed bin.	118
Fig. 5-13 The normal distribution of Present study and Jung approach results in Vestas V90 3.0 MW at 12 m/s wind speed bin.	118
Fig. 5-14 Estimated data obtained through MCS and measured data in Vestas V90-3.0 MW.	119
Fig. 5-15 Forecasting for wind power production and measured power production with the predicted variation($\pm 3\sigma$).	121
Fig. 5-16 MAE results from measured power data and predicted power data obtained through MCS.	123
Fig. 5-17 The accuracy for the variation of power production in medium-term. ...	126
Fig. 5-18 The accuracy for the variation of daily power production in long-term. ...	126
Fig. 5-19 Measured power production, predicted power production and predicted variation(P95) from 4/29 to 5/02 in medium-term.	127
Fig. 5-20 Measured power production, predicted power production and predicted variation(P95) from 4/30 to 5/03 in medium-term.	127
Fig. 5-21 Measured power production, predicted power production and predicted variation(P95) from 5/01 to 5/04 in medium-term.	128

List of Tables

Table 1-1 Numerical Weather Prediction(NWP) Global Models.....	4
Table 2-1 Numerical weather prediction model in counties.....	14
Table 3-1 IGBP-Modified MODIS 20-category Land Use Categories.	29
Table 3-2 16-category Soil Categories.	30
Table 3-3 Summary of microphysics options.	35
Table 3-4 Summary of land surface model.	40
Table 3-5 Configuration of domain and scheme for real-time wind power forecasting system.	43
Table 3-6 Forecasting error depends on LSM(Noah, Noah-MP) in medium-term.	54
Table 3-7 MAE and RMSE using regression model with UV method and without UV method.	63
Table 3-8 Comparison of measured data and predicted data using neural network models.	66
Table 4-1 Summary of Hang-won wind turbine #3.	86
Table 4-2 Statistical measures for wind speed in the medium-term wind power forecasting.	90
Table 4-3 Error of wind speed are classified into three periods in long-term.	90
Table 4-4 Statistical measures for hourly wind power production in the medium-term wind power forecasting.	94
Table 4-5 Statistical measures for hourly wind power production in the long-term wind power forecasting.	94
Table 4-6 Statistical measures for daily wind power production in the long-term wind power forecasting.	94
Table 5-1 Prediction accuracy of power production according to MCS.	122

요 약

풍력터빈은 자동으로 제어하는 시스템으로 구성되어 있기 때문에 정기적으로 유지보수를 해야 한다. 유지보수를 수행할 때 작업자의 안전을 확보가 필요하다. 또한, 운전하지 못하는 동안 발생하는 손실액을 확인하여 손실액을 최대한 줄이도록 노력해야 한다. 이를 위해 풍력터빈의 운영에 필요한 풍속 및 풍향과 같은 기상정보와 풍력터빈의 발전량을 제공받는다.

국내 전력시장은 발전회사에서 보유한 발전원들의 공급가능용량을 바탕으로 입찰경쟁을 진행하고 있다. 입찰경쟁을 위한 공급가능용량을 제공하는데 어려움이 존재하여 국내에서는 신재생에너지 전력용량을 입찰경쟁으로 진행하고 있지 않다. 하지만, 전력시장을 운영하는 관리자 입장에서는 공급된 신재생에너지의 전력용량만큼 타 발전원의 공급전력용량에 영향을 미치고 있기 때문에 가격발전계획을 수립할 때 무시를 할 수 없다. 풍력발전단지의 발전량은 인위적으로 조절이 불가능하므로 추정된 발전량에 대한 risk 분석을 위해 예보에 대한 변동성 정보를 제공해야 한다.

본 연구에서는 WRF 모델을 이용하여 실시간 풍력발전량 예보 시스템을 통해 생산 가능한 발전량을 제공하고 Monte Carlo Simulation을 이용하여 예보정보에 대한 변동성 정보를 제공하고자 한다. 실시간 풍력발전량 예보 시스템을 구축을 위해 필요한 요소들을 선정하여 개념설계와 상세설계를 수립했다. 개념설계에서는 예보 목적, 예보 시간, 예보 해상도, 예보 대상, 예보 방법을 결정한다. 상세설계는 하드웨어 및 소프트웨어 설치, 하드웨어 성능 테스트, WRF 모델의 최적화, 통계모델, 예보 일정으로 구성되었다.

예보 목적은 풍력터빈의 운영계획이고, 예보 시간은 3일 중기예보와 14일 장기예보로 선택되었다. 예보 해상도는 1시간과 1일이고, 예보 대상은 단일 풍력터빈으로 행원풍력3호기이다. 예보 방법은 기상수치모델인 WRF 모델을 선택하였다. WRF 모델을 설치하고 모델의 성능을 극대화하기 위해 MPI와 OpenMP를 결합한 hybrid 병렬연산을 선택하였다. WRF 모델의 최적화에서는 지표면 모델인 Noah와 Noah-MP의 예보

정확도를 검토하여 Noah-MP를 최종적으로 선택하였다.

풍속 및 풍향 데이터를 u-speed와 v-speed로 분해하는 과정인 UV법을 제시하였다. 회귀모델과 신경망모델에 UV법을 도입하여 풍속 및 풍향의 예보 정확도를 검토하였다. 풍속 및 풍향 데이터를 사용할 경우 편차만 고려하여 잘못된 방향으로 풍향을 조정하지만, u-speed와 v-speed를 사용할 경우 방향성을 고려하여 풍향을 조정하였다.

풍력발전량 예보의 변동성을 평가하기 위해 WRF 모델에 내포된 풍속 변동성과 출력곡선으로부터 발생할 수 있는 출력변동성을 고려하였다. WRF 모델의 풍속 변동성은 AWS 데이터의 RMSE 결과를 근거로 산출하였다. 출력곡선의 변동성은 제안된 추정식과 공기밀도에 의한 변동성을 반영하였다. 제안된 추정식은 실측 데이터와 비교하여 검증하였다.

중기예보의 발전량 정확도는 MAE가 180.32 kWh, RMSE가 245.61 kWh로 나타났고, 데이터의 일치도를 나타내는 IOA는 0.71로 나타났다. 장기예보의 발전량 정확도는 MAE가 4.28 MWh, RMSE가 5.644 MWh로 나타났고, 데이터의 일치도를 나타내는 IOA는 0.51로 나타났다.

중기예보의 변동성 예보는 평균 76.7%로 예보 정확도를 나타냈다. 시간대별 변동성 예보는 3일 예보기간동안 최저 58.8%에서 최대 94.7%까지 나타났다. 장기예보의 변동성 예보는 평균 80.8%로 예보 정확도를 나타냈다. 일별 변동성 예보는 14일 예보기간 동안 최저 62.1%에서 최대 92.9%까지 나타났다. 장기예보의 변동성 예보는 6일까지 85% 이상의 정확도를 보여줬고, 7일부터 정확도가 급격하게 떨어졌다.

Summary

A wind turbine must be regularly maintained in order to manage a wind turbine by a automatic control system. When workers perform a maintenance of a wind turbine, it is necessary to secure their safety. In addition, they should try to minimize the amount of loss while not driving a wind turbine. For those condition, weather information are provided such as the wind speed including a power production in wind turbine.

The domestic electric power market is bidding competition based on the supply capacity of power generation companies. There is a difficulty in providing available supply capacity for bidding competition, and the domestic renewable energy power capacity is not proceeding to bid competition. However, since the manager of the power market affects the power supply capacity of the other generation source as much as the power supply of the renewable energy supplied, it can not be ignored when the price development plan is established. Uncontrolled power production in wind farms should be informed of uncertainty for risk analysis of estimated power generation.

This study proposes a real time wind power generation forecasting system using WRF model and provide variation information about power production forecast using Monte Carlo Simulation.

The conceptual design and detailed design were established for real-time wind power forecasting system. The conceptual design determines the purpose of the forecast, the forecasting time, the forecasting resolution, the forecasting target and the forecasting method. The detailed design consisted of hardware and software installation, hardware performance test, WRF model optimization, statistical model, and forecast schedule.

The forecasting purpose was the operation plan of the wind turbine, and the

forecasting time was selected as the 3-day forecast and the 14-day forecast. The forecast resolution is 1 hour and 1 day, and the target is a single wind turbine, Hangwon no. 3. WRF model, numerical weather prediction model, was selected. The hybrid parallel computing(MPI + OpenMP) was selected in order to install the WRF model and maximize the performance of the model.

The UV method, which is a process of decomposing wind speed and wind direction into u-speed and v-speed, is proposed. The prediction accuracy of wind speed and wind direction was examined by implementing the UV method to a regression model and a neural network model.

When the data of the wind speed and direction are used without the UV method, the wind direction was adjusted in the wrong direction only considering the deviation. However, when the u-speed and v-speed are used with the UV method, the wind direction is adjusted in consideration of the directionality.

The variation of the wind speed in the WRF model was calculated based on the RMSE results of the AWS data. The variation of a power curve reflected the proposed variation estimation formula and the variation of the air density. This formula is verified by comparing with the measured data.

The accuracy of power production for the medium-term forecast was 180.32 kWh for MAE and 245.61 kWh for RMSE, and IOA for data consistency was 0.71. The accuracy of the long-term forecast was 4.28 MWh for MAE, 5.64 MWh for RMSE, and 0.51 for IOA.

The variation forecast of the medium-term showed a forecast accuracy of 76.7%. The hourly forecast variation ranged from 58.8% to 94.7% during the three-day forecast period. The variation forecast of the long-term showed a forecast accuracy of 80.8%. The daily forecast variation ranged from 62.1% to 92.9% during the 14-day forecast period. The forecast variation of long-term forecasts was more than 85% accurate by the 6th day, and accuracy declined sharply from 7th.

1. 서 론

1.1. 연구배경

일기예보는 온도, 바람, 비, 눈, 습도 등의 정보를 많은 사람들에게 전달해준다. 이 정보들은 다양한 분야에서 사용되고 있는데, 농사를 짓는 농민들에게는 날씨정보를 전달하여 농작물을 관리할 수 있도록 도움을 준다. 항공기가 이륙하는 공항에서는 안전한 항공운행을 위해 바람 및 기상특보를 항시 전달받고 운영한다. 더욱이, 태풍과 같은 기상특보는 전 국민들을 대상으로 사전에 전달하여 태풍피해에 대비할 수 있도록 도움을 준다. 이와 같이 다양한 분야에서 사용되고 있는 일기예보는 바람과 밀접한 관계가 있는 풍력분야에서도 도움을 주고 있다.

풍력은 바람에너지를 전기에너지로 전환해주는 풍력터빈을 이용하여 전기수요자에게 전기를 공급한다. 바람은 기상상태에 따라 변화무쌍하기 때문에 풍력터빈은 다른 발전원에 비해 전기생산량은 전기공급자가 인위적으로 조절하기엔 한계가 있다. 이로 인해 전기공급자는 풍력에너지를 전기수요자들에게 원활한 전력을 전달하는데 어려움이 존재한다. 기상예보는 미래의 잠정적인 바람의 세기를 예보하여 특정지역에 있는 풍력터빈의 전기생산량을 예보하여 도움을 줄 수 있다. 이는 풍력터빈의 전기생산량을 극대화하면서 화력발전소와 같은 발전원을 최소화하여 소비되는 화력연료들을 감소시켜 경제력을 확보할 수 장점이 있다.

풍력발전단지의 운영자는 지속적이고 안정적인 풍력터빈의 운영을 위해 정기적으로 풍력터빈을 정비해야 한다. 이를 위한 정기점검계획을 수립하기 위해서는 고려되어야 할 요소로 바람의 상태를 고려해야 한다. 강풍일 때 점검자는 풍력터빈 내부에서 안전을 확보할 수 없기 때문이다. 또한, 경제적인 측면에서도 점검하는 동안에는 풍력터빈을 가동하지 못함으로 가동하지 못한 전력량만큼 손실액이 발생하게 된다.

이러한 상황들을 고려한 정기점검계획을 수립하기 위해서는 기상예보가 필요하다.

기상예보는 우리나라 기상청에서 슈퍼컴퓨터를 활용하여 예보하고 있다. 기상예보는 기온, 강수, 낙뢰 등의 정보를 1시간 간격으로 알려주는 예보부터 계절별 기온, 강수량, 엘니뇨, 라니냐 전망을 연 4회 발표하는 예보까지 다양한 예보를 운영하고 있다[기상청, 2018]. 이런 기상예보를 운영하기 위해서는 기온, 바람, 압력과 같은 기상정보를 수집하고, 기상요소들의 시간 변화를 정의한 물리방정식을 모델링한 기상수치모델을 수행한다. 기상수치모델은 복잡하고 대용량 자료를 처리해야하므로 슈퍼컴퓨터가 필요로 한다.

기상청에서 운영하고 있는 기상예보는 한 가지 분야에 특화된 예보가 아니므로, 아쉽게도 풍력분야에 바로 적용하기엔 부족한 부분이 존재한다. 일반적으로 제공되는 기상정보의 높이는 약 10 m 이지만, 풍력터빈의 허브높이는 5MW급 기준으로 약 100 m이므로 격차가 존재한다. 또한, 예보범위가 넓어 풍력발전단지의 개별 풍력터빈마다 상세한 정보를 얻기엔 부족하다. 마지막으로, 예보된 풍속에 생산 가능한 전기생산량을 제공하고 있지 않다.

이런 한계점들은 기상청에서 해결할 문제가 아니고, 풍력발전단지 운영자, 풍력터빈 유지보수 작업자, 전력계획 수립자와 같이 풍력분야에서 기상정보를 필요로 하는 엔지니어들이 해결해야할 문제로 생각한다.

1.2. 국내외 연구동향

해외에서는 오래전부터 활발하게 풍력발전량 예보 시스템을 연구하여 상업화하였다[Foley et al., 2012]. 특히, 유럽지역에서는 7개국, 22기관이 협력하여 2002년부터 Anemos project가 진행되었다[Greor et al., 2012]. Anemos project는 기상수치모델과 통계모델을 연구 개발하여 예측 정확도를 향상시키는데 목적을 두었다. Anemos project의 후속 project로 Anemos plus project를 수행했다. Anemos plus project는 예보 데이터를 필요로 하는 사용자들에게 제공하는 비즈니스 프로세스를 개발 및 연구해 왔다.

풍력발전량 예보 시스템의 구조는 크게 물리모델, 통계모델, 하이브리드 모델로 총 3가지로 분류한다. 물리모델은 기상수치모델, CFD 등 물리현상을 엔지니어링 툴로 개발한 모델을 의미한다. CFD는 작은 지역을 해석할 때 사용하고 있으며, 기상수치 모델은 넓은 지역을 해석할 때 사용하고 있다. 주로 기상수치모델이 현업용으로 많이 쓰이고 있다. 기상수치모델은 기상관측자료를 수집하고, 수집된 기상관측자료와 기상현상을 정의한 방정식을 통해 미래의 기상상태를 예보하는 방법이다. 대표적으로 미국, 유럽연합, 영국, 일본이 각각 개발한 모델을 운영하고 있다(table. 1-1).

미국은 NOAA(National Oceanic and Atmospheric Administration)에서 운영하는 GFS(Global Forecast System) 모델을 운영하고 있다. 전지구 모델로 수평해상도는 50 km이고, 예보기간은 총 240시간으로 10일을 예보한다. 예보 간격은 3시간 간격으로 데이터를 생성하고 있으며, 하루에 총 4번 수행한다. 유럽은 ECMWF(European Centre for Medium-Range Weather Forecasts)를 운영하고 있다. 전지구 모델로 수평 해상도는 79 km이고, 예보기간은 총 240시간으로 10일을 예보한다. 영국은 Unified Model을 운영하고 있으며, 수평 해상도는 10 km이고, 총 6일을 예보한다. 일본은 Global Spectral Model을 운영하고 있고, 수평 해상도는 20 km이고, 총 264시간으로 11일을 예보한다.

이상과 같이 Global model은 지구 전체를 모델링하여 기상현상을 예보함으로써 슈퍼컴퓨터가 필수적이다. 풍력분야에서 제한된 지역의 기상정보를 필요로 하는 경우에는 과도한 자원을 소모하는 경우이다. 이에 반해 특정지역만 기상현상을 예보하는 Regional model이 존재하는데, 대표적으로 WRF(Weather Research and Forecasting) 모델이 있다. WRF 모델은 1970년대 초반 NOAA와 국립환경예측센터 NCEP(National Centers for Environmental Prediction)에서 공동으로 개발한 모델로 현업기상모델로 사용되고 있다.

통계모델은 예보데이터를 시간순서에 따라 변동 또는 경향성을 분석하는 시계열 분석과 과거데이터를 학습시켜서 입력된 값에 따라 출력값을 도출하는 인공지능으로 분류된다. 시계열 분석은 대표적으로 ARIMA(Autoregressive integrated moving average)[Kavasseri and Seetharaman, 2009], Fuzzy logic[Stefanakos and Vanem, 2018], Kalman filter[Zuluaga et al., 2015], Grey predictor[EI-Fouly et al., 2006]이 있다. 인공지능 방법은 대표적으로 ANN(Artificial Neural Network)[Maqsood et al,

Table 1-1 Numerical Weather Prediction(NWP) Global Models

Global Model	Developed by
Global Forecast System (http://www.emc.ncep.noaa.gov/index.php?branch=GFS)	National Oceanic and Atmospheric Administration
Integrated Forecast System (https://www.ecmwf.int/en/research)	European Centre for Medium-Range Weather Forecasts
Unified Model (https://www.metoffice.gov.uk/research/modelling-systems/unified-model)	UK Met Office
Global Spectral Model (http://www.jma.go.jp/jma/en/Activities/nwp.html)	Japan Meteorological Agency

2005], SVM(Support Vector Machine)[Kusiak et al., 2009]이 있다. 하이브리드 모델은 통계모델과 기상수치모델을 조합한 모델을 의미한다. 일반적으로 기상수치모델에서 예보된 데이터를 바탕으로 통계모델에 입력한 후 예보정확도를 보정하는 방법을 채택한다.

해외에서는 많은 모델들이 출시되어 사업화되어 있다. Prediktor[Landberg, 2001]는 물리모델을 적용한 단기예보 시스템이다. European Wind Atlas[Troen and Petersen, 1998]을 개발하는 동안 얻은 경험을 바탕으로 개발되었다. 기상수치모델에서 풍속과 풍향을 얻은 후 타겟 사이트에 맞게 변형한 다음에 마지막으로 출력곡선을 사용하여 출력량을 예측하였다. 여기서, 풍력터빈의 후류영향을 같이 고려했고, MOS(Model Output Statistics) module을 기상수치모델에서 나온 풍속과 풍향데이터에 적용함으로써 기상수치모델의 시스템 에러를 최소화했다. 또한, 기상수치모델에서 타겟 사이트로 전달할 때 Riso에서 개발한 Wind Atlas Analysis and Application program[Mortensen et al, 1993]을 적용하였다. Prediktor는 California에서 검증되었고, 연평균 MAE(Mean Absolute Error) 기준으로 14.2%의 오차를 보여줬다.

Previento[Focken et al., 2001]는 Oldenburg 대학교에서 기상수치모델을 사용하여 개발하였고, Energy & Meteo Systems GmbH(EMSYS)에서 운영하고 있다. Prediktor와 같은 절차를 도입했다. 추가로, 기상조건에 따라 풍속과 출력에 대한 불확도를 평가하여 정보를 제공하였다. 독일 내에서 출력예보에 대한 NRMSE(Normalized Root Mean Square Error) 기준으로 약 6%의 오차를 보여줬다.

LocalPred and RegioPred[Marti, 2002]은 Spanish National Renewable Energy Center와 Spanish Research Center for Energy, Environment, and Technology에서 공동으로 개발한 모델이다. 기상수치모델인 MM5를 도입하여 72시간을 예보하였다. 격자 간격으로 1 km보다 작게 하기 위해서 CFD tool를 결합하였다. 또한, ARMA 모델, 나셀 풍속계를 이용한 클러스터 출력곡선 추정 등 다양한 통계모델을 도입하였다.

WPPT(Wind Power Prediction Tool)은 DTU(the Technical University of Denmark)에서 개발한 모델로 단일 풍력발전단지, 다수의 풍력발전단지, 그리고 넓은 지역(덴마크의 서부)을 대상으로 예보를 한다. WPPT는 온라인으로 기상수치모델에서 예보된 데이터와 풍력발전단지에서 측정된 SCADA(Supervisory Control And Data Acquisition) 데이터를 획득하고 통계모델인 conditional parametric model을[Nielsen et al, 2000] 사용

하였다. 또한, 예보 결과에 확률분포의 분위수를 도입하여 불확도를 평가하였다. WPPT의 예보 정확도는 NRMSE 기준으로 9 ~ 27 %로 나타났다[Cutler et al, 2006].

Zephyr는 WPPT와 Prediktor를 결합하고 확장한 버전이다[Giebel et al., 2002]. WPPT와 Prediktor의 장점을 조합하여 구성하였고, 오직 기상수치모델의 예보데이터만 사용이 가능하면 Prediktor만 수행되고 풍력발전단지에서 온라인으로 모든 데이터를 수집할 수 있으면, WPPT의 통계모델도 같이 수행되도록 구성되었다.

Cassandra는[Gaertner et al., 2003] Gamesa Energia, Barlovento Recursos Naturales, 그리고 MOMAC group of the University of Castilla-La Manchad에서 공동으로 개발한 예보 시스템이다. MOMAC 연구팀에서 개발한 중규모 기상수치모델을 도입하였고, MOS를 기초로 개발된 통계모델을 추가로 결합했다. 풍속에서 출력을 산출하기 위해 다변량 회귀 모형으로부터 도출된 풍력발전단지의 출력곡선을 이용하였다. 예보 정확도는 결정계수(R^2)을 기준으로 0.69 ~ 0.87로 나타났다.

AWPPS(ARMINES Wind Power Prediction System)은 프랑스에서 개발한 예보 시스템이다[Kariniotakis et al, 2002]. AWPPS는 첫 번째로 시계열 분석을 하는 단기예보를 수행한다. 예보기간은 총 10시간이고 출력량을 도출한다. 두 번째로 장기예보를 수행한다. 장기예보는 SCADA 데이터와 기상수치모델의 예보데이터를 수집하여 fuzzy neural networks를 수행한다. 예보기간은 총 72시간이다. 세 번째로 단기예보의 데이터와 장기예보의 데이터를 결합하여 최종적으로 예보데이터를 생성한다. 마지막으로 risk index uncertainty를 도입했다. AWPPS는 아일랜드에서 HIRLAM(High Resolution Limited Area Model)보다 RMSE 기준으로 약 20% 향상된 결과를 보여줬다[Costello et al., 2002].

WEPROG은 2가지의 메인 모델을 포함하고 있다[Lang and jorgensen, 2006]. 매 6시간마다 온라인으로 SCADA 데이터를 취득하여 출력 예측 시스템을 수행하고, 기상수치모델이 추가로 수행된다. 기상수치모델은 서로 다른 물리옵션을 적용하여 다양한 결과를 도출한 앙상블 모델로 구축되어 있다. 출력 예측 시스템은 기상수치모델의 예보데이터(풍속, 풍향, 온도, 표면 플럭스, 난류 운동 에너지)와 출력간의 상관성을 분석하여 출력을 예보한다.

Sipreolico는 스페인에서 설치된 모든 풍력터빈들의 SCADA 데이터의 80%를 획득하여 수행된 모델이다[Sanchez et al., 2002]. 9개의 모델을 사용하였고, 모델들은 2개의

그룹으로 분할되었다. 첫 번째 그룹은 dynamic linear model로 풍속을 출력으로 환산해주는 다항식 모델이다. 두 번째 그룹은 비모수 모델들을 모았다. 각 모델의 파라미터는 RLS(Recursive Least Square) 알고리즘 또는 칼만필터를 이용하여 추정되었다.

GH Forecaster는 Garrad Hassan에서 개발한 예보 시스템으로 다변량 선형회귀법을 사용하여 특정 사이트의 SCADA 및 측정데이터와 기상수치모델의 데이터를 통합한 후 특정 사이트에 적합하도록 전환했다[Gow, 2003]. 여기서, 개발된 site-specific model은 기상수치모델과 사이트의 관계성을 통계모델을 적용하여 분석하는 모델이다. GH Forecaster는 지속성 모델(Persistence model)에 비해 54% 향상된 모델로 밝혀졌다.

SOWIE(Simulation Model for the Operational Forecast of the Wind Energy Production in Europe)는 Eurowind GmbH에서 개발된 예보 시스템이다[Lange and Focken, 2005]. SOWIE는 물리모델로 GFS, HIRLAM의 데이터, SCADA 데이터를 사용한다. 하루 4번 수행하며 총 예보기간은 120시간이다.

EPREV는 Wind to Power model, AR(Auto Regressive) 모델, NNAM(Neural Network Assembling Model)을 채용했다[Rodrigues et al., 2007]. EPREV는 글로벌 기상수치모델인 ECMWF, GFS, Meteo-France로부터 공급된 데이터와 중규모 모델인 MM5, ALADIN을 사용하였다.

eWind는 AWS Truewind사에서 개발한 모델로 기상수치모델로부터 초기 및 경계조건으로 사용될 데이터를 받아 ForeWind NWP(Numerical Weather Prediction)을 수행한다[Bailey, 1999]. 또한, 풍력발전단지에서 설치된 기상탑 데이터를 취득하여 통계모델을 개발하였다. 사용된 통계모델은 SMLRs, NNs, SVM, FLC, PCA이고, 지속성 모델에 비해 50% 향상된 결과를 도출하였다[Zack et al., 2000].

Visionpoint는 미국 WindLogics사에서 개발하였고, RUC(Rapid Update Cycle), NAM(North American Model), GFS의 데이터를 통계모델에 적용하였다. 채용된 모델은 SVM이고, 풍속과 출력간의 관계성을 분석하였다. Visionpoint는 매달 새로운 기상자료를 얻은 후 모델을 재훈련을 하여 지속적으로 모델이 개선되도록 유지하였다. NMAE 기준으로 1시간 예보 오차는 5% ~ 12%으로 나타났다.

PowerSight는 3TIER Environmental Forecast Group에서 개발한 모델로 7일과 84시간 예보를 1시간 간격으로 제공한다. 기상수치모델의 환경을 6가지 종류로 도출된 데

이터를 선택하고 있고, 단기예보에는 SCADA data를 추가로 사용하여 정확도를 향상시켰다. 또한, ramp forecasting 기법을 도입하여 급격하게 변동하는 발전량을 예측하였다. 풍력발전량의 불확도는 분위수 회귀법을 도입하여 평가하였다.

Precise Stream는 CFD 기법을 도입한 meso-microscale 기상모델로 단일 풍력터빈, 단일 풍력발전단지, 다수의 풍력발전단지를 예보하는 모델이다(Precision, 2009). 도메인의 격자 간격은 최소 1 km까지 구성이 되며, 전체 도메인 크기는 수백 km까지 확장이 가능하다. 하지만, CFD 기법의 단점인 고성능 컴퓨터 자원이 필요하다. Precise Stream의 장점은 다른 모델에 비해 복잡지형에서도 좋은 정확도를 보여준다. 예보 정확도는 NMAE 기준으로 2.5% ~ 17%로 나타났다(Kelly, 2008).

Wang et al.(2011)은 예보된 값에 대한 불확도를 평가하여 연구하였다. 사용된 모델은 WRF 모델이고, WRF 모델에서 채용되는 scheme에 따라 상이하게 예보된 결과들을 시나리오로 구성하여 risk를 분석하였다. Quan et al.(2014)은 하나의 값으로만 제공하는 point forecasting은 risk 분석에 필요한 정보를 제공하지 못함으로 neural network을 사용하여 발전량의 신뢰구간을 제공하였다. Yan et al.(2015)은 풍력발전량 예보에 대한 불확도를 평가하는 방법으로 probabilistic, scenario, risk index로 3가지로 분류하였다.

Pinson et al.(2009)은 Horns Rev 풍력발전단지에서 1년 동안 수집된 데이터를 기반으로 ensemble-based probabilistic을 이용하여 불확도 예보를 평가하였다. 특히 풍력발전단지에서 수집된 데이터를 사용하여 발전단지에 적합한 출력곡선을 도출하였다. 출력곡선을 생성하기 위해 polynomial regression을 도입했고, orthogonal fitting method를 추가로 도입하여 최적화하였다.

국내에서는 한국에너지기술연구원에서 풍력발전 예보시스템 KIER Forecaster를 개발하였다(Kim et al., 2006). KIER Forecaster는 신경망회로, 다중선형회귀, 자기회귀 등 다수의 통계모형을 도입하였고, 기상청에서 제공하는 측정자료를 사용하였다. KIER Forecaster는 월정단지에 있는 기상탑자료, 기상청의 3시간 간격 예보 풍속, KIER Forecaster에서 예보된 풍속 및 발전량을 제공한다.

Kim et al.(2010)은 제주도의 AWS 지점들을 군집분석하여 그룹을 형성한 후 일단위로 풍속을 예보하는 3가지 다른 모형에 대해서 실험했다. 실험대상 모델은 전이함수 모형, 시계열자기회귀모형, 신경망모형이고, 과거 1, 2, 3일전 데이터들을 사용하여 예

보하였다. 전이함수모형과 신경망모형이 예보 정확도가 높았으나, 신경망모형은 전이함수모형에 비해 복잡한 모형구조를 가지고 있음에도 불구하고 비슷한 예보 성능 나타냈다.

Park et al.(2010)은 기상수치모형을 이용하여 제주도에서 운영 중인 풍력발전단지별로 풍속을 예보하였다. 한경, 수산, 행원 풍력발전단지에서 1시간 간격으로 48시간 풍속 예보를 수행하여 12시간 이내는 22~23%, 48시간 이내는 25~29%의 오차를 보여줬다. Kim et al.(2010)은 Park et al.(2010)가 사용한 기상수치모형과 MOS(Model Output Statistics)을 이용하여 48시간 풍속 및 발전량을 예보하였다. 국내 기상청에서 운영 중인 MOS를 추가로 도입하여 24시간 예보일 경우 결정계수가 0.53으로 나타났고, 48시간 예보일 경우 결정계수가 0.30으로 나타났다. 이는 기상청에서 제공된 MOS 모델이 예측한 지점은 현업용 풍력터빈의 위치한 지점과 떨어져 있고, 각 예보지점의 환경도 차이가 존재하여 오차가 큰 결과를 도출하였다. 따라서 풍력발전량 예보를 위한 독립적인 MOS 모델의 개발이 필요하다.

Kim et al.(2014)은 풍속 예보모델을 AWS(Automatic Weather System) 데이터를 사용하여 연구하였다. 사용된 통계모델은 k-nearest neighbor, locally weighted linear regression와 M5 model tree 알고리즘이고, 1시간 앞의 풍속을 예보하였다. 예측 근거로 사용되는 요소들은 시간, 경향, 과거의 풍속 예측 값 등 많은 요소들이 내포될수록 예보 모델의 정확도가 높다고 밝혔다.

Kim et al.(2016)은 풍력발전량을 예보하기 위해 앙상블 기법을 사용하였다. 앙상블 기법에 도입된 기상수치모형의 데이터들은 다중모델, 다중물리에 의해 6종류이로 분류되어 사용되었다. 해양예측 모델인 KMA-WW3의 추가로 기존 단일자료의 예측정확도 보다 풍속의 상관계수가 1.4% 향상된 결과를 도출하였다. Park and Hur(2017)은 설치된 풍력터빈의 출력이 제작사 출력곡선에서 명시된 출력과 상이하기 때문에 풍력터빈에서 측정된 풍속과 출력을 사용하고, 다변량 회귀모형을 기반으로 한 SVM을 도입하여 단일 풍력터빈의 풍력발전량을 예보하였다. 이는 풍속을 출력으로 예측하는 기법으로써, 외부환경 또는 풍력터빈의 종류 및 위치에 의존적이다.

1.3. 연구목적

풍력발전량 예보 분야는 풍력발전단지의 원활한 운영을 위하여 필요한 분야이다. 실시간 풍력발전량 예보 시스템은 초단기, 단기, 중기, 장기에보로 분류될 수 있다. 초단기 예보는 6시간 이내를 예보하며 풍력터빈을 제어하는데 사용하거나 실시간으로 전력 그리드(Grid) 망을 안정적으로 운영하는데 사용된다. 단기에보는 24시간 이내를 예보하며 풍력발전단지의 효율적인 제어, 실시간 전력시장 운영 등에 사용된다. 중기에보는 3일(72h)까지 예보하며 풍력터빈의 유지보수 및 운영계획, 전력시장에서의 전력수급계획 등과 같은 계획수립에 사용한다. 장기에보는 3일 이상을 예보하며 주로 장기적인 풍력발전단지의 정기점검 계획에 사용한다.

풍력발전량 예보 대상은 지역구 단위로 다수의 풍력발전단지 또는 개별 풍력발전단지가 될 수 있다. 또한, 연구목적으로 특정 풍력터빈이나 기상탑이 될 수 있다. 예보 대상이 정해지면 이에 따른 시간 해상도가 필요하게 되는데 10분 간격, 1시간 간격 3시간 간격 등 다양하게 결정할 수 있다. 이후에는 예보방법을 결정해야 하는데 물리모델로써 기상수치모델, 통계모델로써 시계열 모델, 또는 두 가지 이상의 방법을 결합한 하이브리드 모델이 존재한다.

상기 언급한 바와 같이 실시간 풍력발전량 예보 시스템을 구축함에 있어서 결정해야 할 요소들이 많다. 본 연구에서는 풍력발전량 예보를 연구하기에 앞서 필요한 요소들은 결정하고 원활하게 연구를 수행할 수 있도록 실시간 풍력발전량 예보 시스템의 개념설계와 상세설계를 정의하였다. 또한, 풍력터빈의 원활한 운영계획을 수립하기 위해 기초 데이터로 사용될 수 있는 풍속 및 발전량을 예보하고자 한다. 지속적인 운영계획의 수정 및 보완을 위해 하루에 1번 예보정보가 갱신되도록 구축하였다. 이를 제주대학교 행원3호기를 대상으로 수행하고자 한다.

마지막으로 예보된 풍력발전량에 대한 변동성을 평가함으로써 예보된 풍력발전량의 신뢰구간을 제시할 수 있도록 연구하였다. 평가된 변동성 요소는 기상수치모델인 WRF 모델에서 예보된 풍속 변동성과 풍속을 발전량으로 환산해주는 출력곡선에 대한 변동성을 평가하였다.

2. 실시간 풍력발전량 예보 시스템 개념설계

실시간 풍력발전량 예보 시스템을 구축하기 위해 첫 번째 단계로 개념설계를 구성하여 수행하였다. 개념설계는 예보 목적, 예보 시간, 예보 해상도, 예보 방법, 예보 대상으로 구성하였다. 본 장은 먼저 기상수치모델을 종류와 국가별로 운영 중인 모델을 소개하였다. 그 다음 예보 목적, 예보 시간, 예보 해상도, 예보 방법, 예보 대상 순으로 설명하였다. 여기서, 예보 시간은 예보하는 전체 기간을 의미한다. 예를 들면, 단기예보인 경우 전체 예보 시간은 24시간으로 0시부터 24시간까지 예보 데이터를 공급함에 목적을 둔다. 예보 해상도는 정해진 예보 기간 동안 기상정보를 제공하는 시간간격을 의미한다.

2.1. 기상수치모델

기상수치모델은 기상관측자료를 수집하고, 수집된 기상관측자료와 기상현상을 정의한 방정식을 통해 미래의 기상상태를 예보하는 방법이다. 기상수치모델을 수행하기 위해서는 기본적으로 기상자료가 필요하다. 기상자료는 다양한 측정기기들을 활용하여 기상정보들을 수집하고 있다. 풍속계, 풍향계, 온도계, 압력계 등 많은 측정기기들을 통합으로 구성된 장비들을 활용한다. 대표적으로 자동기상관측장비(AWS, Automatic Wather System), 부이(Buoy), 인공위성, 기상관측선, 기상 레이더, 라이오존데 등을 사용한다. 기상자료를 근거로 대기의 물리현상을 구현한 방정식계를 수치로 해석하여 앞으로 발생 가능한 기상상태를 예보한다(figure 2-1). 여기서, 방정식을 계산하기위한 슈퍼컴퓨터를 이용하여 단시간에 계산을 수행한다. 국내 기상청은 슈퍼컴퓨터 4호기인 CRAY XC40을 운영하고 있으며, 기상수치모델은 영국에서 개발한

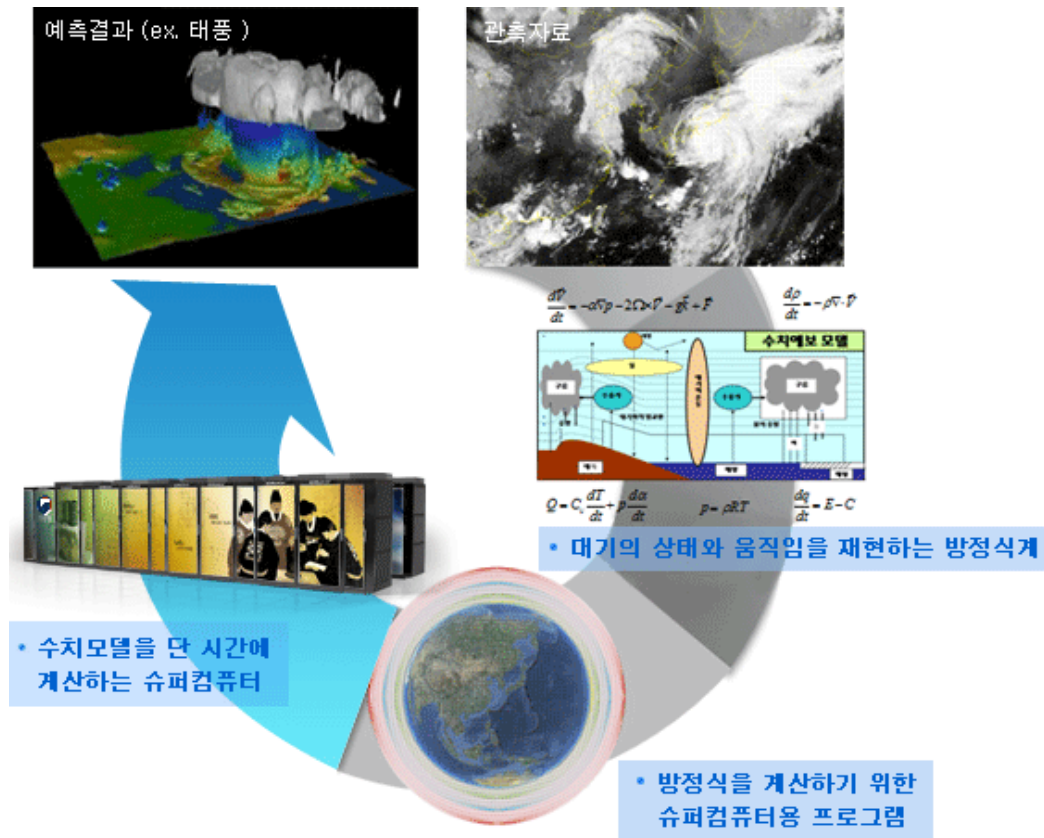


Fig. 2-1 The concept map of the numerical weather prediction model
(reference source : http://web.kma.go.kr/aboutkma/intro/supercom/model/model_concept.jsp)

UM(Unified Model)을 사용하고 있다. 전지구를 대상으로 수평해상도는 10 km이고, 수직층은 70층으로 구성하여 하루 4회에 걸쳐 12일 동안의 예보자료를 제공한다. 이는 전지구 날씨 예보하는데 목적을 두고 있다. 지역예보 시스템으로는 수평해상도가 12 km이고, 수직층은 70층으로 동일하게 구성되었다. 하루 4회에 걸쳐 87시간의 예보자료를 제공한다. 이는 아시아 날씨를 예보하는데 목적을 두고 있다. 국지예보 시스템으로는 수평해상도가 1.5 km이고 수직층은 70층으로 구성되었다. 하루 4회에 걸쳐 36시간의 예보자료를 제공하고 이를 한반도 전역에 대한 날씨를 예보하는데 목적을 두고 있다.

미국합중국 해군(U.S Navy) 소속인 FNMOC(Fleet Numerical Meteorology and Oceanography Center)는 전지구 모델인 NAVGEM(NAVy Global Environmental Model)을 운영하고 있다. NAVGEM은 수평해상도가 37 km이고, 수직층은 50개층으로 구성되었으며 총 180시간을 예보하고 있다. 미국합중국 공군(Air Force Wather Agency)는




Fig. 2-2 GSM, LFM, MSM domain

(reference source : <http://www.jma.go.jp/jma/indexe.html>)

주로 지역모델로 사용되는 WRF(Weather Research and Forecasting) 모델을 도입하여 특정지역을 대상으로 기상예보를 수행하고 있다. NOAA(National Oceanic and Atmospheric Research) 산하 단체인 NCEP(National Centers for Environmental Prediction)은 전지구 모델인 GFS(Global Forecast System)모델을 수행하여 약 50 km의 수평해상도를 갖는 기상자료를 생성하여 제공하고 있다. 이 GFS모델에서 생성된 예보자료를 GFS 자료라고 부르고 있으며, 전 세계적으로 FTP 서버를 통해 공급하고 있다. 지역모델로는 미국북부지역을 예보하는 NAM(North American Mesoscale Forecast System)을 12 km까지 해상도를 높여 운영하고 있다. 또한, RAP(Rapid Refresh) 모델을 운영하고 있으며, RAP 모델은 시간대별로 기상 데이터를 갱신하여 최대 3 km 수평해상도인 예보자료를 제공하고 있다.

유럽중기예보센터(ECMWF, European Centre for Medium-range Weather Forecasts)은 18개 나라에서 공동으로 운영하고 있는 기관으로 기상수치모델을 이용하여 기상을 연구하는 기관이다. ECMWF에서 운영 중인 기상수치모델은 ECMWF로 불리며 수평해상도는 79 km, 31km이고, 수직층은 60개층, 137개층으로 구성되었다. 지속적으로 모델의 성능을 향상시키고 있으며, 2020년도에는 ERA6를 준비하고 있다.

JMA(Japan Meteorological Agency)는 전지구 모델인 GSM(Global Spectral Model)을 사용하고 있다. GSM은 수평해상도가 약 20 km이고, 수직층은 0.01 hpa까지 100개층으로 구성되었고, 총 264시간의 예보자료를 제공하고 있다. GSM에서 생성된 자료를

Table 2-1 Numerical weather prediction model in counties

Model	Agency	Country	Resolution
WRF	Air Force Weather Agency (AFWA)	US	45 km, 15 km
NAVGEM	Fleet Numerical Meteorology and Oceanography Center (FNMOC)		Global model, 50 km Forecasting time : 72h
GFS	NOAA National Weather Service (NWS)		Global model, 50 km Forecasting time : 240h
NAM(WRF)			North American, 12 km Forecasting time : 84h & 36h
RAP			13 km, Forecasting time : 18h
ECMWF	ECMWF	Europe	79km, 31km Forecasting time : 240h
UM	Met Office	UK	10km Forecasting time : 144h
GSM	JMA	Japan	20km Forecasting time : 264h

바탕으로 MSM(Meso-Scale Model)과 LFM(Local Forecast Model)을 도입하여 수평해상도가 각각 5 km, 2 km이고, 수직층은 76개층으로 구성되었다. 영국은 Met Office(Meteorological Office)에서 운영하고 있는 UM모델을 도입하고 있으며, 수평해상도는 약 10 km, 수직층은 70개층으로 구성되었다.

GFS, WRF는 모델의 source code를 공개하고 있으며, ECMWF는 ECMWF와 협약된 국에게 source code를 공개하고 있다. UM, LFM, MSM은 source code를 공개하지 않고 있다. GFS, WRF, ECMWF는 전세계적으로 활발하게 연구 및 현업용으로 사용되고 있고 사용자 커뮤니티가 활성화 되어 있다.

2.2. 예보 목적 및 예보 시간

풍력발전량 예보 시스템의 개념설계 단계에서 첫 번째 단계로 예보 목적을 들 수 있다. 풍력발전량의 예보 목적은 실시간 그리드 운영, 풍력터빈 제어, 전력시장 운영, 유지보수 계획 등 다양한 목적을 두고 있다[Jung and Broadwater, 2014; Tascikaraoglu and Uzunolu, 2014; Okumus and Dinler, 2016; Kim and Hur, 2018]. 실시간 그리드 운영은 전력망의 주파수가 정적상태로 지속적으로 유지되도록 관리를 하는데, 풍력터빈인 경우 풍속 변화에 따라 출력 변동성이 급격함으로 이를 대비한 예보 데이터가 필요하다. 여기에 적합한 예보는 그리드 특성을 고려하여 초단기 예보가 적합하다.

풍력터빈은 안정적으로 운전하기 위해 실시간으로 제어를 한다. 제어하는데 필요한 요소는 일반적으로 풍속과 로터 속도이다. 이 요소들은 현재 상태 값을 터빈 제어기에 보내므로 앞으로 일어날 터빈 상태에 대해서는 제어하지 못한다. 이를 위해 예보 데이터를 사전에 제어기에 전달함으로써 앞으로 일어날 상황에 대해서 대비할 수 있다. 이는 곧, 풍력터빈의 하중 감소를 의미하고 하중을 감소시키는 만큼 터빈은 안정적으로 운전될 수 있다(Holmberg, 2016). 이 목적에 부합되는 예보 시간은 24시간 이내 정보를 요구하기 때문에 초단기 예보에서 단기예보까지로 판단된다.

우리나라 전력시장은 발전회사에서 보유한 발전원들의 공급가능용량을 바탕으로

입찰경쟁을 진행하고 있다(고용준 등, 2001; 한국동서발전, 2008). 이는 근본적으로 발전회사에서 공급 가능한 전력용량을 산출해야 하는데, 풍력터빈인 경우 바람의 예측이 불가능하면 전력공급용량을 산출할 수 없다. 아직 국내에서는 신재생에너지 전력용량을 입찰경쟁으로 진행하고 있지 않다. 하지만, 전력시장을 운영하는 관리자 입장에서는 공급된 신재생에너지의 전력용량만큼 타 발전원의 공급전력용량에 영향을 미치고 있기 때문에 가격발전계획을 수립할 때 무시할 수 없다. 이를 위하여 풍력터빈의 발전량 예보는 전력시장에서 필요한 정보가 될 예정이다. 전력시장에서 요구되는 발전량의 예보기간은 발전계획신고기간(한국전력거래소, 2004)을 고려하여 최소 24시간에서 34시간의 데이터가 필요하다. 이를 통해 전력시장에서 예보정보를 전달할 경우 단기예보 또는 중기예보를 수행하여 예보정보를 전달해야 한다.

풍력터빈은 자체 제어시스템을 통해 자가 점검하면서 운전을 하는 시스템이다. 문제가 발생할 경우 오류 메시지를 표출하면서 정지를 하는데, 정지를 함으로써 전기를 생산하지 못하는 상황은 풍력터빈의 운전자에게 금전적인 손해를 준다. 이 상황을 최소화하기 위해서 정기적으로 유지보수 일정을 계획하고 이에 따라 수행한다. 여기서, 유지보수 계획을 수립하기 위해서는 필요한 정보가 존재하는데, 그 중 하나가 풍속 및 발전량 예보 데이터이다(Holmberg, 2016). 풍속 예보 데이터는 풍력터빈의 유지보수 작업자의 안전을 확보할 수 있는 요소로 사용되고, 발전량 예보 데이터는 터빈 운영자의 손실액을 산출할 수 있는 요소로 사용될 수 있다. 유지보수 계획은 풍력터빈의 보수내용에 따른 준비기간을 확보하기 위해 장기적 계획이 필요하고, 보수일로부터 2~3일에 최종점검을 할 수 있는 풍속 및 발전량 예보 데이터를 필요하기 때문에 예보기간은 중기와 장기예보를 선택을 하는 게 합리적이라고 판단된다.

2.3. 예보 해상도 및 예보 대상

예보 해상도는 예보정보를 제공하는 시간간격을 의미한다. 예를 들면, 24시간 단기 예보에서 예보 해상도가 1시간이라면, 전체 24시간 예보시간 동안 1시간 간격으로 예보정보가 담겨져 있다는 것을 의미한다. 예보 해상도는 예보 방법에 따라 달리 질 수

있으나, 예보 시간이 짧을수록 예보해상도도 짧아지고, 예보시간이 길어지면, 예보해상도도 같이 길어지는 방향으로 가야 한다.

예보 해상도는 초 단위, 분 단위, 시간 단위, 일 단위로 구분된다고 할 수 있다. 초 단위 또는 분 단위는 급격한 변동성을 파악해야 하는 실시간 그리드 운영, 풍력터빈의 제어에 필요한 예보해상도라고 할 수 있다. 분 단위는 1분, 10분 평균자료를 필요로 하는 경우에 쓰일 수 있다. 풍력터빈의 제어 중 하나인 요 제어는 잦은 동작이 필요하지 않으므로 분 단위 예보자료를 필요로 할 수 있다. 시간 단위는 풍력터빈의 출력단위가 Wh단위로 환산하기 때문에 출력량을 표시할 때 쓰인다. 전력시장 운영에서는 전력공급량 단위는 Wh을 사용하기 때문에 전력시장 운영에 쓰일 경우 필수 선택이라고 볼 수 있다. 일 단위는 풍력터빈의 1일 생산량을 표시할 때 사용되며, 1일 생산량을 참고하는 전력시장 또는 풍력터빈의 운영계획에 쓰일 수 있다. 일 단위에서는 풍속을 1일 평균값으로 나타낼 수 있는데, 1일 평균 풍속은 하루 동안의 평균적인 풍속을 의미함으로 참고용으로 사용 할 수 있다.

개념설계단계에서 예보 대상의 선택은 예보 방법과 더불어 상세한 설계절차를 진행하는 상세설계단계에서 예보 위치, 높이 등의 정보를 전달할 수 있으므로 필수적으로 진행되어야 할 단계이다. 예보 대상은 단일 풍력발전단지, 풍력발전단지의 그룹, 단일 풍력터빈, 기상탑 등이 될 수 있다. 풍력발전단지를 선택할 경우 예보 데이터는 발전량 단위로 표현되어야 풍력발전단지의 전체 생산량을 산출할 수 있고, 기상탑을 선택할 경우 예보 데이터는 풍속 단위로 표현되어야 기상탑의 데이터와 비교하는 연구를 진행할 수 있다(Her et al., 2015).

2.4. 예보방법

풍력발전량 예보 시스템의 예보 방법은 크게 3가지로 분류된다. 첫 번째로 물리모델은 물성치와 물리현상을 정의한 방정식을 엔지니어링 툴에 의해 해를 찾아가는 방법으로 기상수치모델과 CFD(Computational Fluid Dynamics)을 들 수 있다. CFD는 유동 현상을 비선형 편미분 방정식인 Navier-Stokes Equation을 유한요소법을 사용하여

유동 문제를 해결하는 하는 틀이다. 주로 풍력발전단지가 복잡지형에 설치되었을 경우 사용하는 방법이다(Castellani et al., 2016). 기상수치모델은 기상요소를 기반으로 물리방정식을 연산하는 모델이다. CFD와 달리 기상현상에 특화된 모델로써 넓은 지역을 해석해야하는 상황에서도 적용이 가능하다. 물리방법은 기상이론에 근거하여 해를 찾아가기 때문에 결과에 대한 해석이 용이하지만, 연산량이 많아 고성능 컴퓨터가 필요하다.

물리모델은 적용된 물리방정식에 따라 도출된 결과가 달라질 수 있기 때문에 다양한 물리방정식을 적용하여 그 결과들을 검토한다. 이 결과들을 종합적으로 분석하여 하나의 결과로 도출하는 방법 앙상블 모델이다. 앙상블 모델은 이상치와 같이 과도한 오차를 도출한 방정식의 결과를 감소시키는 장점을 보유하고 있고, 개질별 또는 시간 개별로 특정 방정식이 우수함을 방영할 수 있는 장점이 존재한다.

통계모델은 과거자료를 분석하여 시계열 분석, 주파수 분석, 패턴 분석 등 사용하여 예보하는 모델이다(Okumus and Dinler, 2016). 통계모델의 종류는 지속적으로 개발되고 있어 다양한 모델들이 존재하고 있지만, 지형, 환경조건, 예보시간 등에 따라 성능차이가 발생하고 있어 독보적인 모델은 존재하지 않는다. 하지만, 초단기예보와 같은 예보 시간이 짧고 기상이 급격하게 변동하는 현상이 아니라면 물리모델보다 정확도가 우수하다고 검증하고 있고, 계산 소요시간이 물리모델에 비해 적다. 이에 비해 통계모델은 solver가 black-box로 되어 있어서 예보결과에 대한 해석이 불가능하다.

통계모델은 크게 시계열 기반, 인공지능 기반으로 다시 분류된다. 시계열 기반은 칼만필터, ARIMA와 같은 시간 도메인에서 분석하는 통계모델이고, 인공지능 기반은 과거 자료를 학습시켜 모델을 구현해가는 통계모델이다. 인공지능의 방법 중 대표적인 모델은 ANN으로 인간의 뇌 구조와 비슷하게 구현하여 학습시키는 모델로서 변형된 모델을 많이 보유하고 있다(Methaprayoon et al., 2007). 하지만, ANN와 같은 학습을 기반으로 구축되는 모델들은 대용량의 자료를 필수적이다.

물리모델과 통계모델의 단점들을 서로 보완하기 위해 두 모델들을 결합한 하이브리드 모델이 많이 개발되고 있다(Afshari-Igder, 2018). 기상수치모델인 WRF와 풍황자원 분석 Tool인 WindSim이 결합된 모델(Efe et al., 2012), MM5와 ANN을 결합한 모델(Salcedo-Sanc et al., 2009) 등이 존재하는데, 물리모델과 통계모델을 결합할 경우 물리모델의 자료가 통계모델의 기초자료로 많이 사용된다. 이는 통계모델은 다년간 수

집된 자료가 필요한데, 이를 물리모델이 대신 공급해줌으로써 단점을 보완할 수 있기 때문이다.

2.5. 예보 시스템 개념설계 프로세스

실시간 풍력발전량 예보 시스템의 전체적인 개념설계의 프로세스는 figure 2-3와 같이 구성하였다. 예보 목적은 실시간 그리드 운영, 풍력터빈 제어, 풍력터빈 운영계획으로 분류될 수 있다. 예보 시간은 초단기 예보, 단기 예보, 중기 예보, 장기 예보로 분류될 수 있고, 예보 해상도는 초 단위, 분 단위, 시간 단위, 일 단위로 분류하였다. 예보 대상은 단일 풍력발전단지, 풍력발전단지 그룹, 단일 풍력터빈, 연구목적인 기상탑 등으로 구성하였다. 예보 방법은 물리방법, 통계방법, Hybrid 방법으로 구성하였다.

본 절은 예보 목적에 따라 개념설계 프로세스를 정립하였다. 실시간 그리드 운영을 예보 목적으로 정할 경우 예보 대상은 단일 풍력발전단지 또는 풍력발전단지 그룹이 될 수 있다(figure 2-4). 이는 풍력발전단지에서 생산되는 전력량은 인근 풍력발전단지 또는 그리드에 연계되어 있는 타 발전원에 영향을 주기 때문이다. 또한, 풍력발전단지의 개별 풍력터빈에 집중하기 보다는 최종적으로 변전소에 전송되는 전력량의 상태에 관심이 많기 때문이다.

실시간 그리드 운영을 감시해야하기 때문에 6시간 이내인 초단기 예보와 1일 이내인 단기에예보를 구성함이 합리적으로 생각된다. 그리드 운영을 실시간으로 운영하기 때문에 중·장기적으로 변화하는 발전량보다는 단기적인 상태 변화에 집중하기 때문에 초단기 예보가 적합하다고 볼 수 있고, 추가로 단기에예보를 선정할 수 있는 이유는 다가오는 이벤트성을 사전에 파악할 수 있기 때문이다.

이에 맞춰 예보 해상도는 초단기 예보를 선택할 경우 초 단위와 분 단위, 단기 예보를 선택할 경우 분 단위와 시간 단위를 볼 수 있다. 전력은 ms단위로 전력을 제어하고 있으므로 최소 sec 단위로 전력량이 변화하는 자료를 제공해야 그리드의 상태에 대비할 수 있다고 생각된다. 또는 분 단위 또는 시간단위로 제공하여 그리드의 주

파수 변동과 같은 이벤트성 상황에 대비해야 한다고 생각한다.

예보 방법은 물리모델, 통계모델, hybrid 모델 3가지 방법을 모두 사용가능하다. 통계모델은 최근 데이터의 경향 및 특성을 이용하여 미래 시점의 상황을 예보함으로써 단기적인 시간에 적합하다. 따라서 통계모델을 사용할 경우 초 단위와 분 단위를 선택하는 것이 합리적이라고 생각된다. 시간 단위를 선택할 경우 하루를 예보하는 단기 예보에 적합하다고 생각된다. 이는 물리모델인 기상수치모델인 경우 짧은 시간에 발생하는 기상현상을 구현할 경우 모델의 spinning time을 고려해야 함으로 초단기 예보에는 부적합하다고 판단된다. Spinning time은 물리모델에서 원활하게 기상정보들이 전달되는 시점을 의미한다. Hybrid 모델은 물리모델과 통계모델을 결합모델이므로 예보해상도에 상관없이 선택이 가능하다.

전력시장의 운영을 예보 목적으로 정할 경우 실시간 그리드 운영의 목적과 함께 예보 대상은 단일 풍력발전단지 또는 풍력발전단지 그룹이 될 수 있다(figure 2-5). 이는 실시간 그리드 운영의 상황과 같기 때문이다. 전력시장은 전력수급계획을 수립하기 위해 입찰경쟁을 채용하고 있는데 이를 위해 필요한 기초적인 자료는 최소 24시간 동안 생산가능한 발전량이다. 따라서 1일 이내를 예보하는 단기예보부터 3일 이내를 예보하는 중기예보까지 필요하다고 판단된다.

예보 해상도는 단기예보를 선택할 경우 시간 단위 중기예보를 선택할 경우 시간 단위와 일단위를 볼 수 있다. 전력판매는 wh단위로 환산되기 때문에 주로 시간대별로 생산가능한 발전량을 요구한다. 예보 방법은 상기 언급한 바와 같이 시간단위와 일단위는 물리모델을 선택할 수 있다. 예외로 시간단위를 통계모델로 구현할 수 있는데, 이는 1일 이내인 단기예보에만 해당되고 통계모델의 한계점인 기상현상을 해석하는 방식이 아니므로 1일 이후에 변화되는 고기압 및 저기압 골에 의해 예보 오차가 급격하게 증가함으로 주의가 필요하다고 할 수 있다. 하지만, 물리모델의 한계점인 spinning time 때문에 1일 이내 중에서도 6시간 이내 예보구간에서는 불확실성한 정보가 제공될 수 있다. 즉, 단기예보는 아직 통계모델과 물리모델의 경계지점이라고 볼 수 있으며 이를 해결하고자 하면 hybrid 모델이 적합하다고 생각된다.

풍력터빈의 제어를 예보 목적으로 정할 경우 단일 풍력발전단지 또는 단일 풍력터빈을 둘 수 있다(figure 2-6). 풍력터빈의 제어는 다가오는 풍속을 사전에 예측하여 풍력터빈에서 발생할 수 있는 하중을 감소시킬 수 있도록 사전에 제어할 수 있도록

도움을 줄 수 있다. 따라서 풍력발전단지 내부에 존재하는 풍력터빈들이 상태를 감시하고 각 풍력터빈의 요잉 상태, 출력량 상태 등을 확인하여 풍력터빈의 하중을 최소화할 수 있다.

풍력터빈의 제어는 실시간으로 제어되고 있고 제어는 현재 터빈상태를 기준으로 제어가 되고 있으므로 초단기 예보에 적합하다고 볼 수 있다. 하지만, 풍력터빈의 입장에서 다가올 풍속의 변동성을 사전에 대비하기 위해서 1일 이내를 예보하는 단기 예보 또한 필요할 수도 있다. 상기 언급한 바와 같이 초단기 예보에는 초단위와 분단위를 선택할 수 있고, 단기에보에는 분단위와 시간단위를 선택할 수 있다. 예보방법은 앞에서 언급한 프로세스와 같이 통계모델, 물리모델, hybrid 모델을 채용할 수 있다.

예보 목적이 풍력터빈의 운영계획이라면 풍력터빈의 제어와 같이 단일 풍력발전단지 또는 단일 풍력터빈이 될 수 있다. 풍력터빈의 운영계획은 자동으로 제어되는 풍력터빈을 정기적으로 관리하기 위함이다. 풍력터빈의 유지보수를 계획하기 위해서는 풍속, 출력량을 고려하게 되는데 이는 풍속에 따라 작업자의 안전을 확보하기 위함이고, 출력량은 유지보수 수행에 의해 발생하는 전력판매금액의 손실액을 사전에 확보하기 위함이다. 단일 풍력발전단지만 고려하는 이유는 타 풍력발전단지에서 수행하는 유지보수 계획은 대상 풍력발전단지에 영향을 주지 않으므로 오직 풍력발전단지 내에서 수행하는 유지보수 계획을 고려하기 때문이다.

운영계획은 1일 이내인 단기에보부터 14일 이내인 장기에보까지 다른 예보 목적에 비해 다양한 폭을 보유할 수 있다. 1차적으로 장기에보를 통해 2주일 동안 유지보수 계획을 수립하고, 중기에보를 통해 다가오는 유지보수의 계획에 적합 여부를 확인한다. 최종적으로 단기에보를 통해 당일 수행하는 유지보수를 수행함에 있어서 돌발 상황에 대응할 수 있도록 사전에 검토할 수 있다. 따라서 풍력터빈의 운영계획에서는 단기에보부터 장기에보까지 다양한 정보를 제공하여 유지보수 계획의 질을 향상시킬 수 있다.

이에 따라 단기에보는 시간 단위, 중기에보는 시간 단위, 일 단위, 장기에보는 일 단위를 적용할 수 있다. 장기에보는 하루 생산량만을 파악하여 잠재적인 전력판매금액의 손실액을 산출하고 1일 평균풍속을 기준으로 잠재적인 유지보수 수행여부를 판단할 수 있게 구성하였다. 중기에보는 일 단위 또는 시간 단위를 채용하여 장기에보

에서와 마찬가지로 1일 평균풍속 및 1일 생산량을 이용하여 유지보수 수행여부를 판단하며 시간 단위를 채용하여 유지보수의 작업시간에 적합한지 최종적으로 확인할 수 있도록 구성하였다. 단기예보는 당일 발생 가능한 급격한 풍속 증가여부를 판단하여 지속적으로 작업자의 안전을 확보할 수 있도록 제공하는 것이 적합하다고 생각된다. 예보 방법은 통계모델, 물리모델, hybrid 모델 모두 채용이 가능하고 통계모델만 단기예보에 채택하는 것으로 구성했고, 물리모델은 중기예보와 장기예보에 채택하는 것으로 구성하였다.

본 연구에서는 예보목적은 풍력터빈의 운영계획으로 선정하였다. 예보기간은 중기예보와 장기예보를 선택하여 중·장기예보의 결과를 도출하였다. 중기예보는 시간단위로 선택하였고, 장기예보는 일단위를 선택하였다. 예보 방법은 물리모델인 기상수치모델을 채택하였다.

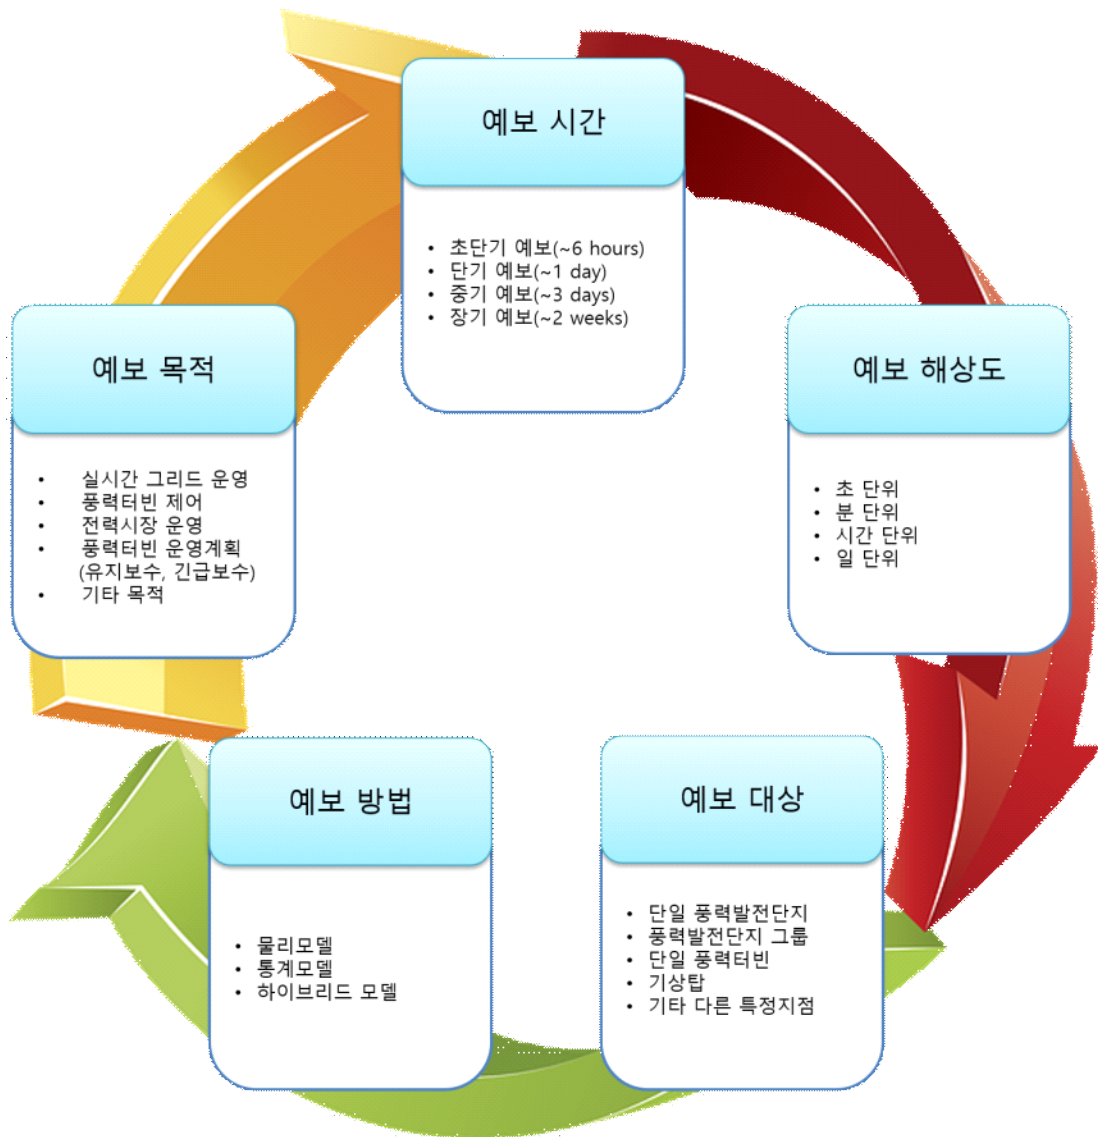


Fig. 2-3 The conceptual design of a real-time wind power forecasting system

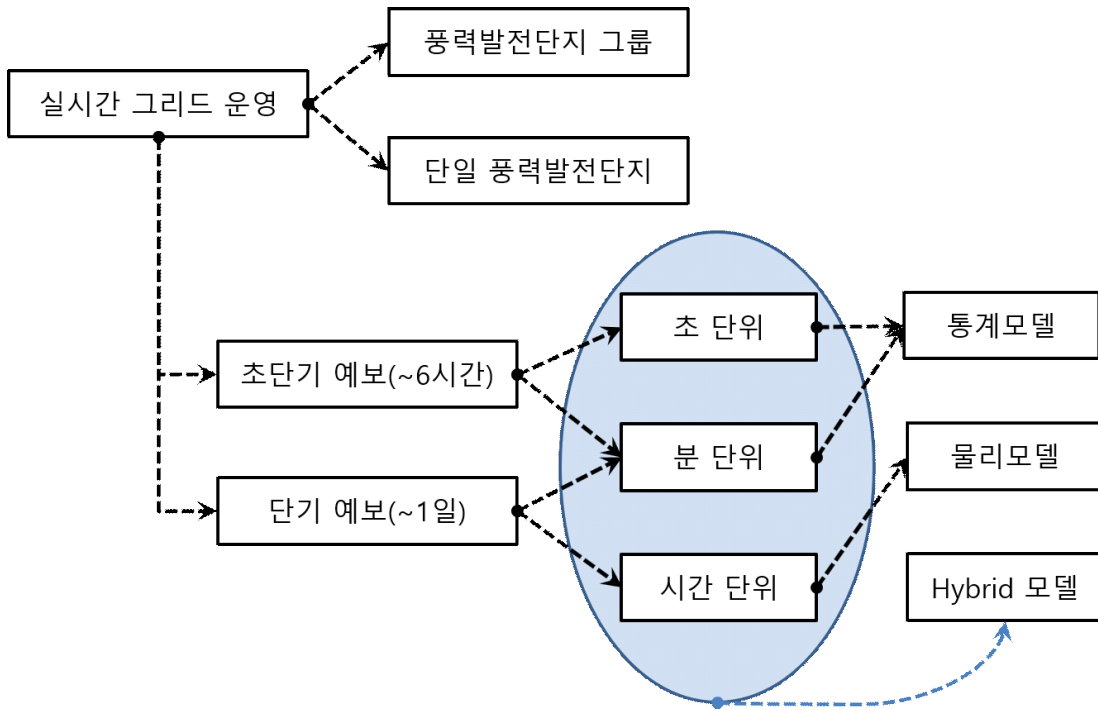


Fig. 2-4 The process of a wind power forecasting system for real-time grid operation.

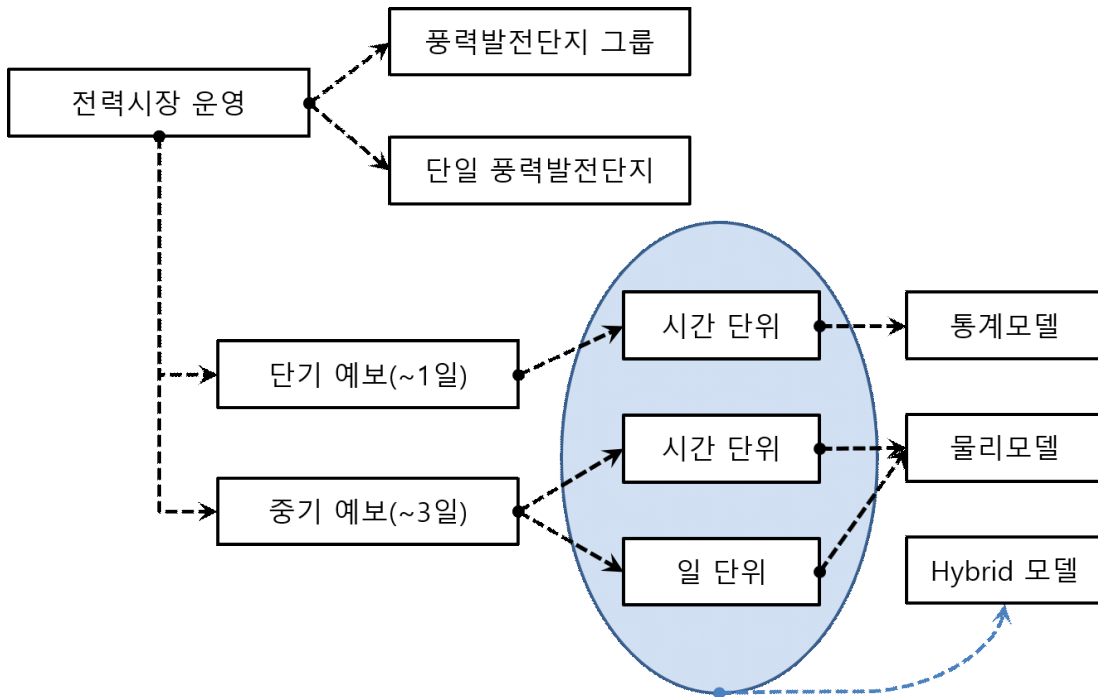


Fig. 2-5 The process of a wind power forecasting system for operation in an electricity market.

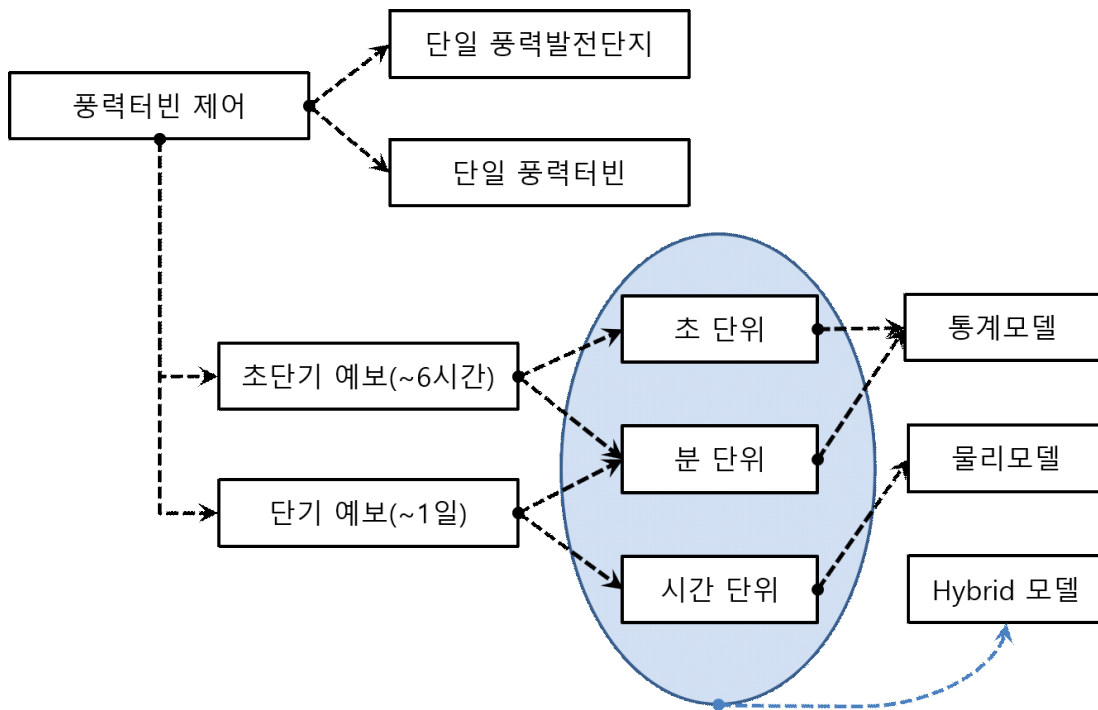


Fig. 2-6 The process of a wind power forecasting system for the control of wind turbines.

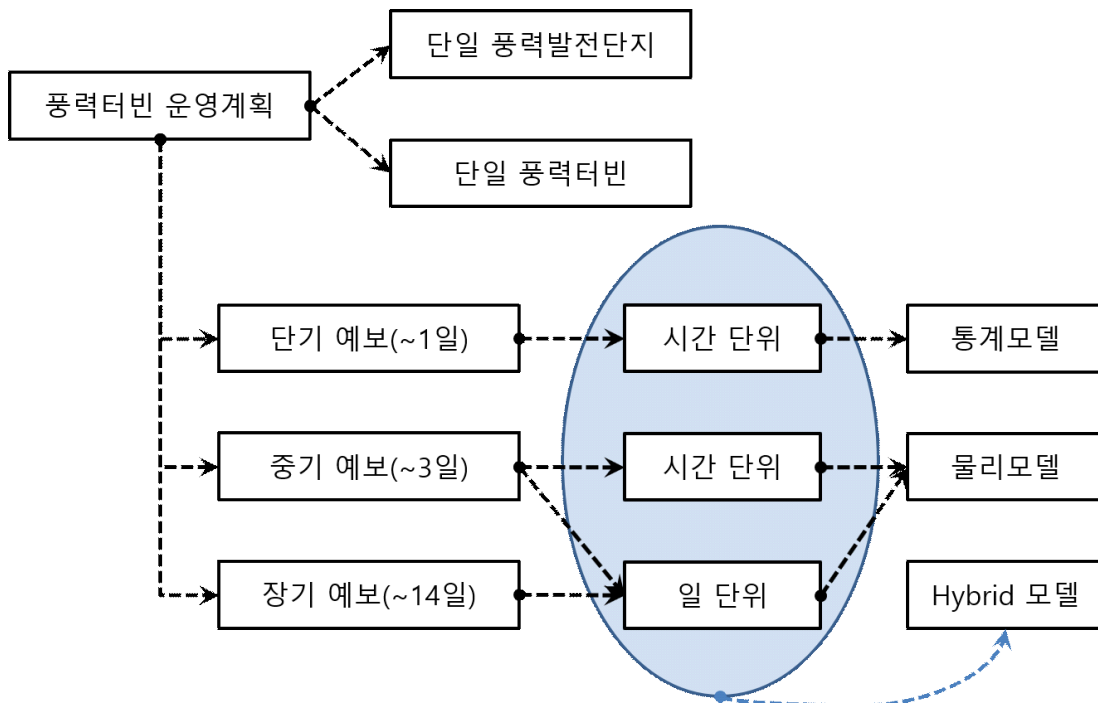


Fig. 2-7 The process of a wind power forecasting system for wind turbine operation planning

3. WRF 모델을 이용한 예보 시스템 상세설계

3.1. WRF configuration

3.1.1. WRF 모델 구성 및 설치

본 연구에서는 예보방법으로 물리모델인 기상수치모델을 선정하였다. 기상수치모델 중 현재 기상 연구용 및 풍력발전량 예보분야에서 많이 활용되고 있는 WRF 모델을 선정하였다. WRF 모델은 미국 국립기상연구소 NCAR(National Center for Atmospheric Research)와 NOAA(National Oceanic and Atmospheric Research)산하 단체인 국립환경예측센터 NCEP(National Center for Environmental Prediction)에서 공동으로 개발한 기상수치모델로써 현업용으로 NCEP에서 운용중이다.

WRF 모델은 역학을 처리하는 방법에 따라 ARW(Advanced Research WRF)와 NMM(Nonhydrostatic Mesoscale Model)으로 분류된다. NMM 코어는 NCEP에서 개발하여 주로 미국지역에 적합하게 설계되고 운영하고 있고, ARW 코어는 NCAR에서 개발하여 범용성을 보여주고 있다(Bernardet, 2009). ARW 코어를 사용할 경우 WRF-ARW라고 불리며, 대체로 WRF라고 줄여서 불린다.

WRF 모델은 전처리 과정인 WPS(WRF Preprocessing System)와 모델 수행단계로 구분된다. WPS는 기상자료 및 토지피복자료, 지형자료 등을 WRF 모델에서 처리 및 사용할 수 있도록 자료들을 정제하는 과정이다. WRF는 중규모 모델로써, 전지구 모델에서 예보한 자료를 받고 특정 지역 및 구역을 해상도를 높이고자 수행하는 모델이다. WPS에서는 주로 전지구 모델에서 예보한 기상자료들을 분석자가 설정한 구역에 맞게 필터링하는 과정이라고 할 수 있다.

기상자료는 다른 자료들과 다르게 GRIB(General Regularly-distributed Information in Binary form)으로 보급된다. GRIB 포맷은 WMO(World Meteorological Organization)

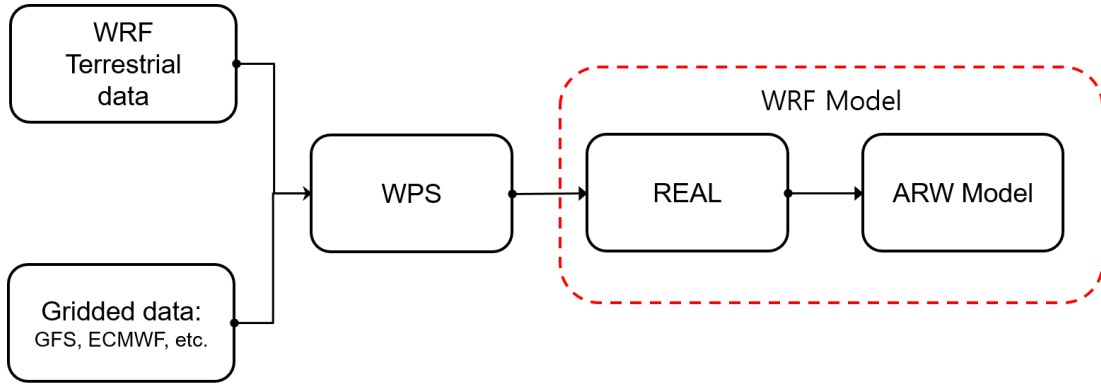


Fig. 3-1 WRF modeling system flow chart.

에 의해 표준화된 포맷으로 WRF 모델도 GRIB 포맷을 채용하고 있지만, 계산단계에서는 NetCDF(Network Common Data Form) 포맷으로 사용함으로 자료 변환이 필수적이다. 이 자료 변환을 WPS 단계에서 수행해 주고 있다. 또한, 기상자료와 지형자료는 계산단계에서는 각 자료의 지점들을 동기화가 필요함으로 WPS에서 처리한다.

WRF model의 단계에서는 real 단계와 ARW model 단계가 존재한다. Real 단계는 WPS 단계에서 정리된 기상자료와 지형자료를 ARW model 단계에서 모델을 수행할 수 있도록 초기 자료와 경계 자료를 예보 간격으로 자료를 생성해주는 단계이다. Real 단계에서 생성된 초기 및 경계자료들을 ARW model에 전달하여 최종적으로 모델을 수행한다.

WRF 모델을 설치하기 위해서는 의존성 프로그램이 필요하다. 의존성 프로그램은 WRF 모델의 설치를 위해 사용되는 라이브러리 파일을 제공한다. 상기 언급한 NetCDF 프로그램이 대표적인 의존성 프로그램이다. 또한 NetCDF 프로그램을 설치하기 위해서는 zlib, PNG, JasPer에서 제공되는 라이브러리 파일이 필요함으로 이 3가지 프로그램도 사전에 설치되어야 한다. 본 설치방법은 부록(appendix)에 첨부하였다.

본 연구에서 사용된 compiler는 intel compiler 12.04이고, NetCDF 4.1.3, WPS 3.8.1 WRF 3.8.1로 설치되었다. NetCDF와 WPS, WRF는 동일한 compiler로 구성되길 추천하고 있다. 따라서 intel compiler로 의존성 프로그램들을 설치하였다.

지상 데이터(Terrestrial data)는 고도 자료, 식물 자료, 토양 자료 등을 포함하고 있다. 고도 자료는 지형자료라고도 불리며 지형의 높이를 표현한 자료를 의미한다. 식

Table 3-1 IGBP-Modified MODIS 20-category Land Use Categories.

Land Use Category	Land Use Description
1	Evergreen Needleleaf Forest
2	Evergreen Broadleaf Forest
3	Deciduous Needleleaf Forest
4	Deciduous Broadleaf Forest
5	Mixed Forests
6	Closed Shrublands
7	Open Shrublands
8	Woody Savannas
9	Savanna
10	Grasslands
11	Permanent Wetlands
12	Croplands
13	Urban and Built-Up
14	Cropland/Natural Vegetation Mosaic
15	Snow and Ice
16	Barren or Sparsely Vegetated
17	Water
18	Wooded Tundra
19	Mixed Tundra
20	Barren Tundra

물자료는 토지이용도(Land Use)자료로도 불리며 식물의 종류(table 3-1)를 내고, 토양 자료는 토양의 종류(table 3-2)를 나타낸 자료이다. WRF 모델에서는 지상 데이터를 기본적으로 제공을 하고 있다. 하지만, 해석하고자 하는 구역에 대한 상세한 자료를 보유하고 있으면 WRF 모델에서 입력이 가능한 포맷으로 변환하여 입력을 해주면 예보 정확도에 기여하게 된다. 풍력발전량 예보시스템의 개념단계 및 상세단계에서는 WRF 모델에서 제공하는 기본적인 자료를 사용하고 추후에 예보 정확도의 향상을 위해 지상 데이터의 상세화가 필요하다고 생각된다.

NWP data는 WRF 모델에서 초기 및 경계조건으로 쓰이는 기상자료를 의미한다. 기상수치모델은 초기 및 경계조건에 따라 예보 결과가 상이하게 나타남으로 NWP data는 신중하게 결정되거나, 앙상블 모델로 구성하는 것이 바람직하다. 예보용으로 사용이 가능한 자료는 GFS와 ECMWF 데이터이다. GFS는 미국 NCEP기관에서 공급

Table 3-2 16-category Soil Categories.

Soil Category	Soil Description
1	Sand
2	Loamy Sand
3	Sandy Loam
4	Silt Loam
5	Silt
6	Loam
7	Sandy Clay Loam
8	Silty Clay Loam
9	Clay Loam
10	Sandy Clay
11	Silty Clay
12	Clay
13	Organic Material
14	Water
15	Bedrock
16	Other(land-ice)

하고 있으며, 수평해상도는 1.0° , 0.5° , 0.25° 로 3 종류가 있고, 시간해상도는 3시간으로 최대 384시간까지 제공하고 있다. 수평해상도가 높을수록 격자해상도가 높아 정밀하나 데이터의 용량이 증가하여 NCEP에서 다운로드를 할 때 많은 시간을 소요하게 된다. 이는 풍력발전량 예보 시스템을 실시간으로 운영할 때 다운로드 소요시간으로 인해 WRF의 수행시점이 뒤로 밀리게 되는 현상이 발생하게 된다. 이는 3.2.1 하드웨어 성능에 따른 예보 정확도와 연관된 사항이다. ECMWF는 예보자료를 10일까지 제공하고 있고, 수평해상도는 0.1° 로 약 9 km에 해당되는 격자간격이다. 고해상도 기상자료를 제공함으로써 좋은 정확도를 보여주고 있으나, ECMWF는 협약된 국가를 제외하고는 유료로 제공하고 있어서 협약된 초기에는 GFS를 사용할 수밖에 없다. GFS는 WMO에 의해 무료로 다운받아서 사용할 수 있는 기상수치모델의 자료이다.

마지막으로 도메인의 구성을 고려해야 한다. 도메인은 WRF 모델이 직교좌표계를 채용하고 있으므로 수평 및 수직층을 구성해야 한다.(다른 좌표계도 채용하고 있으나, 특정 구역만 해석할 경우 직교 좌표계를 주로 쓰인다.) 수평간격을 수십 킬로미터부터 수백 미터까지 조밀하게 구성할 수 있다. 이는 풍력발전량 예보 시스템의 목적에

따라 달리질 수 있으며, 주로 예보 대상이 무엇인가에 따라 선택된다. 일반적으로 km 까지는 난류운동에너지를 상수로 가정하는 PBL을 도입하고, km 이하인 m 규모는 난류운동에너지를 추정하는 LES(Large Eddy Simulation)을 구성한다. LES를 적용할 경우 풍력터빈의 이격거리인 약 300 m(블레이드 지름을 80 m, 터빈 이격거리를 블레이드 지름의 3배로 가정한 경우임.)로 구성할 수 있다. PBL를 적용할 경우 1 km에 가깝게 구성할 수 있다. 아직까지 중규모 기상수치모델이 km 규모에서 m 규모 사이를 grey zone이라고 불리고 있고, micro-scale까지 기상정보를 예보할 수 있도록 연구가 계속 진행 중이다(Doubrawa et al., 2018).

Giovannini et al.(2014)의 연구결과에 따르면 WRF 모델은 도메인의 수평간격이 조밀해질수록 지표면에서 해석하는 풍속이 점차 정확도가 높아짐을 알 수 있다. 특히 지표면은 상세한 지형자료를 제공할 경우 지형의 특성이 해석격자에 잘 반영되어 풍속 정확도가 높아진다고 언급하였다. 따라서 정확도 높은 풍속을 예보하기 위해서는 수평간격을 조밀하게 구성하는 것이 합리적이라고 생각된다.

본 연구에서는 WRF 모델의 수평해상도는 첫 번째 도메인(D01)의 수평해상도를 24.3 km로 설정하고 하위 도메인인 두 번째 도메인(D02)은 8.1 km, 세 번째 도메인(D03)은 2.7 km, 네 번째 도메인(D04)은 0.9 km로 구성하였다.(figure 3-2, 3-3) 0.9 km 까지 구성한 이유는 예보 대상이 단일 풍력터빈일 경우 1개의 격자내에 단일 풍력터빈이 위치할 수 있도록 구성하기 위함이다. 또한 추후 LES을 적용한 수평해상도 100 m까지 고려하기 위한 설정방법이다.

WRF 모델은 하위 도메인을 구성하여 도메인의 수평해상도를 조밀하게 구성하는 downscaling 기법(Lo et al., 2008)을 채용하고 있다. 이 downscaling 기법은 WRF user guide에 의하면 상위 도메인과 하위 도메인의 수평해상도 비율을 1:3으로 권장하고 있다. 이를 적용하면 0.9 km부터 3배씩 증가하여 24.3 km가 도출하게 된다. 24.3 km 까지 확장한 이유는 선택된 GFS 파일이 1° 간격으로 약 50 km로 구성되어 있는데 GFS의 격자 1칸이 첫 번째 도메인의 4개로 분할되도록 구성하여 GFS의 기상정보가 서서히 상세해지도록 구성하였다. 또한, 1개의 격자내부에서 급격하게 많은 격자로 분할하는 방식은 WRF 모델에서도 비추천하고 있다.

도메인의 격자수는 첫 번째 도메인인 경우 한반도 전체가 포함되도록 70 × 70으로 구성하였다. 이는 한반도에서 발생하는 고기압 및 저기압을 하위 도메인에 전달하

기 위함이다. 70×70 은 한 격자가 24.3 km이므로 전체 도메인 크기는 가로 1,701 km, 세로 1,701 km이다. 하위 도메인의 격자수는 상위 도메인과 동일한 70×70 으로 구성하였다.

WRF 모델의 수직해상도는 상층기류와 하층기류가 서로 기상상태를 잘 교환하기 위해 구성해야 한다. WRF user guide에서는 수직해상도를 1 km 이내로 구성하기를 권장하고 있다. 이를 반영하기 위해 수직해상도를 1 km 이내로 구성하여 전체적인 기상상태를 해석하기 위한 기본 층을 구성하였다. 게다가 풍력터빈의 허브높이에 해당하는 풍속을 예보하기 위해서 풍력터빈의 허브높이를 수직층에 추가하였다. 이를 풍력용 수직층이라고 정의했고, 0 m ~ 150 m까지 10 m 간격으로 구성하였다. 이 범위는 현재 상업용으로 운전하는 3 MW급 풍력터빈의 전체 높이를 포함하는 높이이다.




Fig. 3-2 WRF model domain D01 and D02.



Fig. 3-3 WRF model domain D03 and D04.

Table 3-3 Summary of microphysics options. *Mixed-phase processes mean that results from the interaction of ice and water particles.

Scheme	Number of Variables	Ice-Phase Processes	*Mixed-Phase Processes
Kessler	3	N	N
Purdue Lin	6	Y	Y
WSM3	3	Y	N
WSM5	5	Y	N
WSM6	6	Y	Y
Eta GCP	2	Y	Y
Thompson	7	Y	Y
Goddard	6	Y	Y
Morrison 2-Moment	10	Y	Y

아니고 눈의 질량 함량을 기반으로 판단한다. WSM3의 계산 절차는 Hong et al. 2006에 기술되어 있다. WSM5 scheme는 WSM3의 ice scheme와 비슷하다. 그러나, 수증기, 비, 눈, 구름 얼음, 구름 수분이 다섯 개의 서로 다른 배열로 배치되어 있어서 과냉각수가 존재하는 scheme이다(Hong et al., 2006). WSM6 scheme는 WSM5 scheme에서 싹눈(graupel)을 추가한 확장된 버전이다(figure 3-4). 다른 scheme들은 싹눈을 고전적인 방법(Lin et al., 1983) 사용하지만, 얼음현상(ice-phase)이 WSM3 scheme에서부터 달라져 눈과 싹눈이 떨어지는 속도, 혼합비 등을 추정하기 위해 퇴적 및 부착에 대한 절차를 추가하였다(Dudhia, 2008).

WSM6 scheme(figure 3-4)에서 Graupel term은 온도가 0°C 이하일 경우 식(3-1)과 같고, 온도가 0°C 이상일 경우 식(3-2)와 같다.

$$S_g = P_{gaut} + P_{iacr}(1 - \delta_3) + P_{raci}(1 - \delta_3) + P_{racs}(1 - \delta_2) + P_{sacr}(1 - \delta_2) + P_{gaci} + P_{gacw} + P_{gacr} + P_{gacs} + P_{sacw} + P_{gdep} + P_{gfrz} \quad (3-1)$$

$$\text{여기서, } \delta_2 = \begin{cases} 1, (q_R \text{ and } q_S < 10^{-4} \text{ kg/kg}) \\ 0, \text{ otherwise} \end{cases}$$

$$\delta_3 = \begin{cases} 1, (q_R < 10^{-4} \text{ kg/kg}) \\ 0, \text{ otherwise} \end{cases}$$

$$S_g = \text{Pgacs} + \text{Pgmlt} + \text{Pgeml} + \text{Pgevp} \quad (3-2)$$

Snow term은 온도가 0°C 이하일 경우 식(3-3)과 같고, 온도가 0°C 이상일 경우 식(3-4)와 같다.

$$S_s = \text{Psaut} - \text{Pgaut} + \text{Piacr}(\delta_3) + \text{Praci}(\delta_3) + \text{Psaci} - \text{Pgacs} - \text{Pracs}(1 - \delta_2) + \text{Psacr}(\delta_2) + \text{Psdep} \quad (3-3)$$

$$S_s = -\text{Pgacs} + \text{Psevp} + \text{Psmlt} + \text{Psem1} \quad (3-4)$$

Rain term은 온도가 0°C 이하일 경우 식(3-5)과 같고, 온도가 0°C 이상일 경우 식(3-6)와 같다.

$$S_R = \text{Praut} + \text{Pracw} - \text{Piacr} - \text{Pgacr} - \text{Psacr} - \text{Pfrz} + \text{Prevp} \quad (3-5)$$

$$S_R = \text{Praut} + \text{Psacw} + \text{Pracw} + \text{Pgacw} + \text{Prevp} - \text{Psmlt} - \text{Psem1} - \text{Pgmlt} - \text{Pgeml} \quad (3-6)$$

Cloud water term은 온도가 0°C 이하일 경우 식(3-7)과 같고, 온도가 0°C 이상일 경우 식(3-8)와 같다.

$$S_c = -\text{Praut} - \text{Pracw} - \text{Psacw} - \text{Pgacw} + \text{Pcond} - \text{Pihftf} - \text{Pihmf} \quad (3-7)$$

$$S_c = -\text{Praut} - \text{Pracw} - \text{Psacw} - \text{Pgacw} + \text{Pimlt} \quad (3-8)$$

Cloud ice term은 온도가 0°C 이하일 경우 식(3-9)과 같고, 온도가 0°C 이상일 경우 식(3-10)와 같다.

$$SI = -Psaut - Praci - Psaci - Pgaci + Pigen + Pidep + Pihtf + Pihmf \quad (3-9)$$

$$S_i = -Pimlt \quad (3-10)$$

여기서 사용된 약어는 다음과 같다.

Pgaci : Production rate for accretion of cloud ice by graupel

Pgacw : Production rate for accretion of cloud water by graupel

Pgacr : Production rate for accretion of rain by graupel

Pgacs : Production rate for accretion of snow by graupel

Psaci : Production rate for accretion of cloud ice by snow

Psacw : Production rate for accretion of cloud water by snow

Pracs : Production rate for accretion of snow by rain

Psacr : Production rate for accretion of rain by snow

Praci : Production rate for accretion of cloud ice by rain

Piacr : Production rate for accretion of rain by cloud ice

Pracw : Production rate for accretion of cloud water by rain

Pgmlt : Production rate for melting of cloud ice to from cloud water

Pgeml : Production rate induced by enhanced melting rate of graupel

Psmilt : Production rate for melting of melting of snow to from cloud water

Psemil : Production rate induced by enhanced melting of snow

Prevp : Production rate for evaporation/condensation rate of rain

Psdep : Production rate for deposition/sublimation rate of snow

Pgdep : Production rate for deposition/sublimation rate of graupel

Praut : Production rate for auto conversion of cloud water to form rain

Psaut : Production rate for auto conversion of cloud ice to form snow

Pgaut : Production rate for auto conversion of snow to from graupel

- Pgevp : Production rate for evaporation of melting graupel
- Psevp : Production rate for evaporation of melting snow
- Pcond : Production rate for condensation/evaporation of cloud water
- Pgfrz : Production rate for freezing of rain water to grupel
- Pimlt : Production rate fo instantaneous melting of cloud ice
- Pihtf : Production rate for heterogeneous freezing of cloud water to from cloud ice
- Pihmf : Production rate for Homogeneous freezing of cloud water to from cloud ice
- Pidep : Production rate for deposition/sublimation rate of ice
- Pigen : Production rate for generation(nucleation) of ice from vapor

단파 및 장파복사는 모델에서 고려되는 모든 요소들의 복사에너지를 담당한다. 단파복사는 태양복사에너지를 의미하고, 장파복사는 지구복사에너지를 의미한다. 단파복사는 태양 스펙트럼으로부터 생성된 파장을 고려한다. 오직 자원은 태양뿐이지만, 대기의 흡수, 반사, 그리고 산란현상들의 절차를 포함하고 있다. 단파복사는 표면의 알베도(albedo)에 의존한다. 장파복사는 주로 지면으로부터 분출 및 흡수되는 열복사에너지를 고려하고, 표면의 온도, 토지피복의 종류에 의존한다.

WRF 모델의 경계층 PBL(Planetary Boundary Layer) scheme는 대기층의 수직방향을 담당하는 scheme이다. 또한, surface layer와 land surface scheme로부터 surface fluxes을 제공받아 대기의 온도, 수분(구름 포함), 수평 운동량(horizontal momentum) 등의 동향을 전체 대기층에 대해서 고려한다.

WRF 모델의 PBL은 경계층 높이 h 를 식(3-11)로 주어진다.

$$h = Rib_{cr} \frac{\theta_{va} |U(h)|^2}{g[\theta_v(h) - \theta_s]} \quad (3-11)$$

여기서, Rib_{cr} 은 critical bulk Richardson number이고, $U(h)$ 은 h 의 높이에서 수직방향 풍속을 의미한다. θ_{va} 는 모델의 최하위층에서 virtual potential temperature이고, θ_s 는 지표면에서의 온도를 나타낸다. θ_s 는 식(3-12)와 같이 나타난다.

$$\theta_s = \theta_{va} + \theta_T \left[b \frac{\overline{(w' \theta'_v)_o}}{w_s} \right] \quad (3-12)$$

여기서, θ_T 는 지표면 근처에서 발생하는 virtual temperature을 의미하고 mixed-layer velocity scale는 $w_s = u_* \phi_m^{-1}$ 와 같이 표현된다. u_* 는 surface frictional velocity scale이고, ϕ_m 는 지표면에서 모델의 상층부까지의 wind profile을 의미한다.

Surface layer에서 level z 까지의 Bulk Richardson number는 식(3-13)으로 정의된다.

$$Rib(z) = \frac{g[\theta_v(z) - \theta_s]z}{\theta_{va} U(z)^2} \quad (3-13)$$

혼합층($z < h$)에서의 turbulence diffusion은 식(3-14)와 같이 정의된다.

$$\frac{\partial C}{\partial t} = \frac{\partial}{\partial z} \left[K_c \left(\frac{\partial C}{\partial z} - \gamma_c \right) - \overline{(w' c')_h} \left(\frac{z}{h} \right)^3 \right] \quad (3-14)$$

여기서, K_c 는 eddy diffusivity coefficient이고, γ_c 는 총 flux에서 발생하는 large-scale eddies들의 영향력이 포함된 지역적 구배(gradient)를 의미한다. $\overline{(w' c')_h}$ 는 역전층(inversion layer)에서의 flux를 말한다.

상기 언급한 식(3-11~3-14)는 Hong et al.(2006)의 연구결과에서 제안한 YSU PBL의 이론이다. Cohen et al.(2015)의 연구결과에 의하면 YSU PBL이 다른 PBL scheme에 비해 경향성을 잘 추정한다고 언급했다. 따라서, 본 연구에서는 PBL scheme에서 YSU model를 채용하였다.

적운 모수화(Cumulus parameterization)는 아격자(sub-grid-scale) 규모에서 얇은 구름 또는 구름들의 영향을 책임진다. 또한, 미해결된 상승기류 및 하강기류들 때문에

Table 3-4 Summary of land surface model.

Scheme	Vegetation Processes	Soil Variables(Layers)	Snow Scheme
5-layer	N	Temperature (5)	none
Noah	Y	Temperature, Water+Ice, Water (4)	1-layer, fractional
RUC	Y	Temperature, Ice, Water+Ice (6)	multi-layer
Pleim-Xiu	Y	Temperature, Moisture (2)	input only

발생된 수직 유동을 고려한다. 이 scheme는 오직 개별 격자 내에서 운영되고, 열 및 습윤 프로파일을 산출한다. 적운 모수화는 이론적으로 오직 10 km 이상의 격자에서만 유효하지만, 때때론 5 km ~ 10 km의 격자 내에서도 도움이 되는 경우도 있다.

LSM(Land Surface Model)는 표면층의 대기 상태, 복사 상태, 미시물리 및 대류 체계의 강수, 토지의 상태 변수 및 지표면 특성에 대한 내부 정보를 사용하여 열 및 습윤 플럭스를 제공한다. 이 플럭스는 PBL에서 수행되는 vertical transport에 대해 낮은 층의 경계조건을 제공한다. LSM은 토양의 여러 층에서 열 및 습윤 플럭스를 처리할 때 다양한 수준의 정교함을 가지고 있으며 초목, 뿌리 및 canopy 영향과 표면에 눈이 덮인 상황을 처리할 수 있다. LSM은 경향성을 제공하지 않지만 표면 온도, 표면 온도 프로파일, 토양 수분 프로파일, 적설 및 canopy 특성을 포함하는 토지의 상태 변수를 업데이트한다.

WRF 모델에서 사용되는 대표적인 LSM을 Table 3-4에 정리하였다. 5-layer scheme는 간단한 LSM로 온도 변수만 고려한다. 토양층은 총 5개 층으로 1, 2, 4, 8, 16 cm의 두께로 구성되었다. 에너지 수지(Energy budget)는 복사, 현열(sensible heat), 잠열(latent heat)을 포함한다. Noah LSM(Chen et al., 2001)는 canopy 수분과 눈의 덮인 영향을 포함한 온도와 수분 변수를 고려한다. 토양층은 총 4개 층으로 10, 30, 60, 100 cm의 두께로 구성되었다. 또한, 식물의 종류, 토양의 조화를 고려하여 뿌리층, 증발산(evapotranspiration), 토양배수(soil drainage), 땅위를 흐르는 빗물(runoff)을 추정한다. Noah LSM는 현열, 잠열을 계산하고, 토양의 얼음 그리고 단편적인 눈 덮인 영향을 예측한다. RUC(Rapid Update Cycle) LSM은 다층구조 토양을 가지고 있다. 토양층은 기본으로 6개 층으로 구성되어 있고, 9개 층 이상으로도 구성이 가능하다. 토양

층의 두께는 6개층으로 구성되었을 경우 0, 5, 20, 40, 160, 300 cm로 구성되었다. 또한, 눈을 다층구조로 구성하여 눈의 두께, 온도, melting algorithms을 통해 눈덩이, 눈 밀도의 변화, 해빙에 의한 물 유입을 추정한다.

상기 언급한 scheme의 종류들은 WRF 모델을 구성할 때 사전에 선정하여 수행하면 물리옵션 최적화 단계에서 간소화하게 진행할 수 있다. scheme의 선택은 WRF 모델의 수행자가 충분한 경험 및 지식을 보유하고 있으면 scheme들의 상호작용을 고려하여 선택할 수 있다. scheme들은 다른 scheme들과 기상정보를 상호교환하면서 수행하므로 scheme의 조합은 중요한 선택사항이다. 하지만, 많은 scheme들의 조합을 전부다 수행하기엔 많은 시간과 자원을 소비하므로 연구사례를 조사하여 선택하는 것이 합리적이다.

Ruiz et al.(2010)은 south america를 대상으로 WRF 모델의 scheme에 대한 민감도를 연구하였다. 지표면 모델에서는 5-layer LSM이 초기 지표면 온도에 따라 예측 정확도가 상이했으며, 대체로 Noah LSM이 높은 정확도를 보여줬다. PBL scheme에서는 대표적인 YSU와 MYJ scheme을 분석하였고, YSU가 온도, 습도, 경계층의 두께를 잘 표현하여 수직방향의 온도변화를 잘 해석했다.

Pei et al.(2014)은 Land surfcae model과 cumulus parameterization에 대한 민감도 연구를 수행했고, scheme의 조합에 따라 예측 정확도를 살펴봤다. 후보 scheme는 LSM에서는 Noah, Noah-MP이고, cumulus parameterization에서는 Kain-Fritsch와 Grell-Devenyi ensemble scheme이다.[Grell and Devenyi, 2002][Kain, 2004] 대체로 wet year와 dry year 모두 Grell scheme와 Noah LSM의 조합이 좋은 결과를 도출했고 Noah-MP LSM은 wet year에서 Noah LSM보다 높은 오차를 나타냈다고 언급했다.

본 연구에서는 선택된 WRF 모델의 scheme들과 도메인 설정환경을 table 3-5에 정리하였다. 하지만, LSM에서는 Noah model과 Noah-MP model를 적용했을 때 기대되는 정확도를 평가하여 최종적으로 선정하였다.

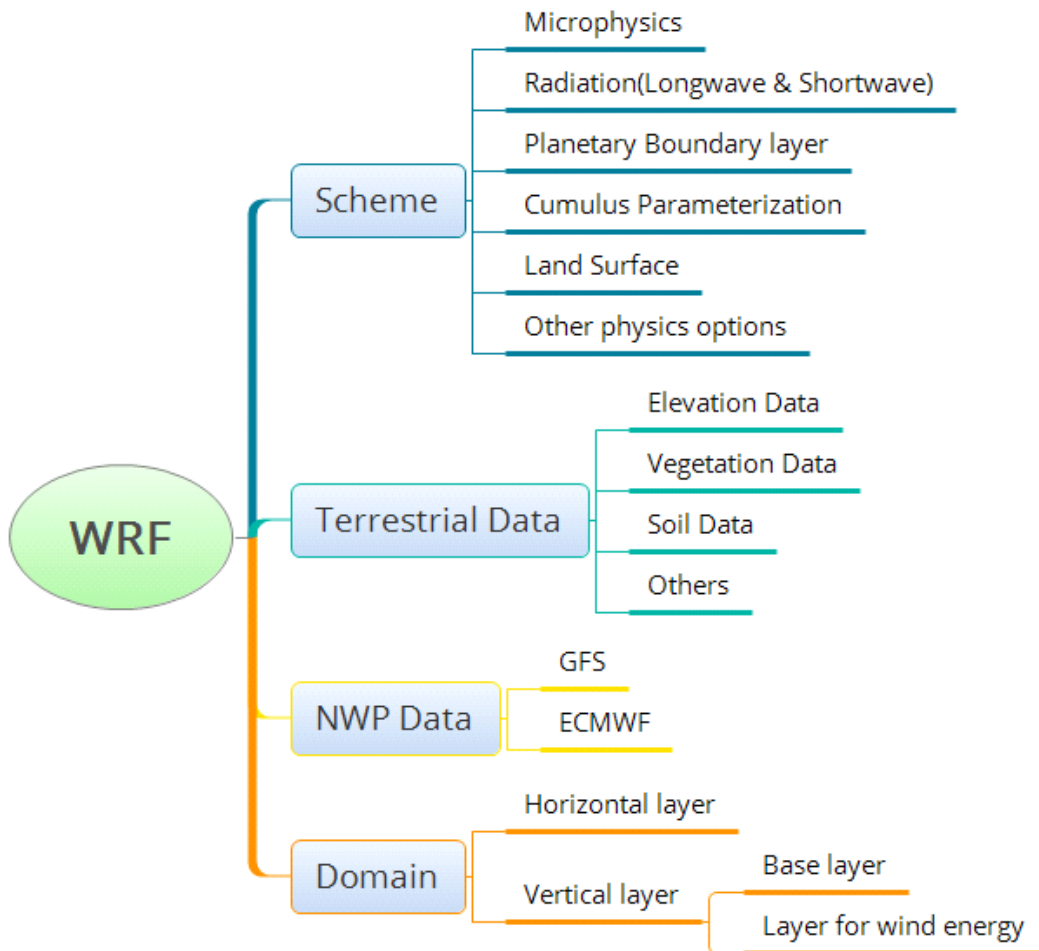


Fig. 3-5 Decision subjects for running WRF model.

Table 3-5 Configuration of domain and scheme for real-time wind power forecasting system. Noah LSM and Noah-MP LSM are selected for the performance optimization in the process of a working design.

Domain No.	D01	D02	D03	D04
Grid points	70 × 70			
Grid spacing	24.3 km	8.1 km	2.7 km	0.9 km
Vertical layer	43(28 layers for the upper air current, 15 layers for wind turbines from 0 m to 150 m)			
Microphysics	WSM 6-class graupel scheme			
Radition(Longwave)	RRTMG scheme			
Radition(shortwave)	RRTMG scheme			
Planetary Boundary layer	YSU scheme			
Cumulus parameterization	Kain-Fritsch scheme	Grell-Devenyi ensemble scheme		
Land Surface Model	Noah LSM vs. Noah-MP LSM			

3.1.3. WRF 모델 수행과정

본 연구에서는 풍력발전량 예보 시스템을 중기예보와 장기예보를 구축하고자 한다. 예보 해상도는 중기예보를 위해 시간단위와 장기예보를 위해 일단위를 선택했다. 예보대상은 단일 풍력터빈이고, 예보 방법으로는 물리모델인 기상수치모델 WRF를 선택했다. WRF의 설정사항은 table 3-5과 같다.

실시간 풍력발전량 예보 시스템을 위한 절차를 수립했다. 미국 NCEP기관에서 GFS 데이터를 다운로드 받고, 한반도 전체를 대상으로 WRF 모델을 수행한다. 이를 수행하게 되면 격자간격이 약 50 km인 GFS 데이터를 24.3 km로 수평해상도를 축소시키는 역할을 한다. 또한, 전력량의 단위인 kWh로 맞추기 위해서는 최소 1시간 간격 데이터가 필요하므로 GFS 데이터의 시간해상도인 3시간을 1시간으로 단축하는 역할을 한다. 이는 첫 번째 단계로써 다음 단계에서 사용될 기상자료로 사용된다.

첫 번째 단계에서 생성된 기상자료는 수평해상도가 24.3 km이고 한반도 전체 기상자료를 내포하고 있으며, 이 기상자료를 1시간 간격으로 저장되어 있다. 이 데이터들은 본 연구에서의 목적과 다른 분야에 사용될 수 있다. 특히 풍력발전단지를 발굴하

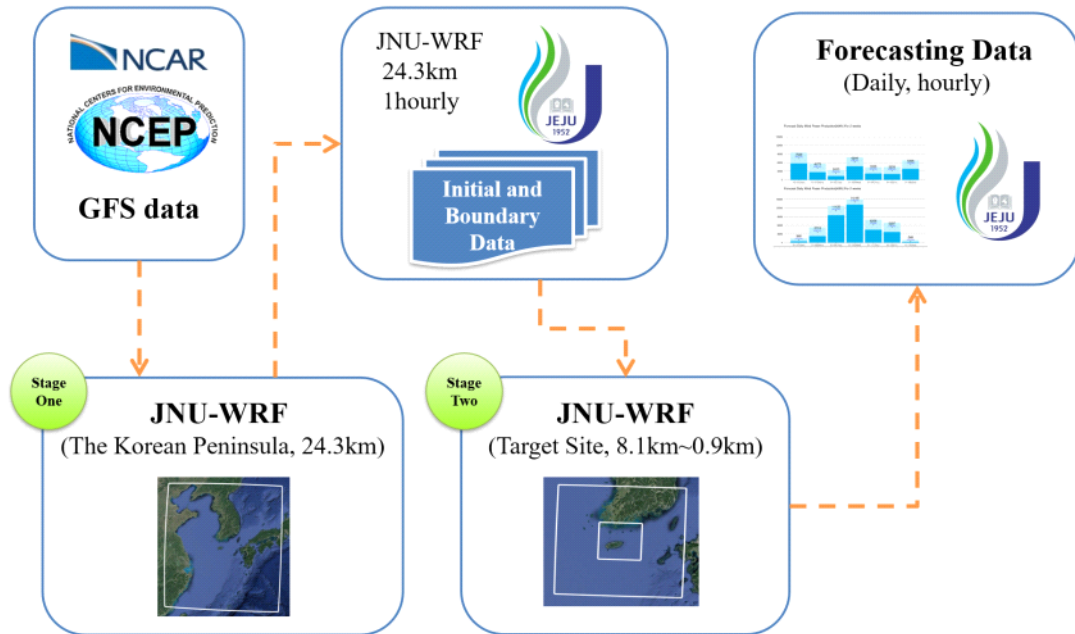


Fig. 3-6 The process of the real-time wind power forecasting system.

는 사업자 입장에서는 한반도 및 해역에서 어느 지점이 풍속이 좋은지 알고 싶어 한다. 비록 예보용 자료이지만, 다년간 저장된 예보자료가 존재한다면, 풍력발전단지를 탐사하는 목적으로도 사용할 수 장점이 있다.

두 번째 단계는 첫 번째 단계에서 제공하는 기상자료를 바탕으로 예보대상을 중심으로 해석을 한다. 첫 번째 단계는 한반도 전체를 대상으로 기상자료를 확보했다면, 두 번째 단계는 예보대상을 중심으로 기상자료를 확보한다. 두 번째 단계에서 예보 지점의 중심이 변경되는 단계이므로 예보대상의 위치는 인근 주변 기상상태를 충분히 해석할 수 있도록 중심이 되도록 설정해야 한다. 이와 마찬가지로 도메인의 크기 도 충분한 주변 기상상태를 충분히 해석할 수 있도록 구성해야 한다. 본 연구에서는 70×70 으로 구성했다. 이 단계에서 중기예보의 수평해상도인 0.9 km까지 downscaling 기법을 사용하여 축소한다.

두 번째 단계가 완료되면 해석된 기상자료를 사용하여 예보대상 위치의 풍속 및 발전량을 예보한다. 이 때 예보정확도를 추가로 향상시키기 위한 통계모델이 존재하면 모델을 수행한 후 예보 자료를 도출한다. 이상과 같이 언급한 절차들을 figure 3-6 에 도시화 하였다.

3.2. 상세설계 프로세스

2장에서 실시간 풍력발전량 예보 시스템 구축을 위한 개념설계를 수행하였다. 도출된 개념설계를 바탕으로 본 장에서는 실시간 풍력발전량 예보 시스템 구축을 위한 상세설계를 수행하여 최종적으로 실시간 풍력발전량 예보 시스템을 구축하고자 한다. 상세설계는 하드웨어 구축, 소프트웨어 구축, 하드웨어 성능 Test, WRF 모델 성능 최적화, 통계 모델, 예보 계획도 수립 순으로 구성했다.(figure 3-7)

하드웨어를 구축하여 WRF와 WRF 구동을 위해 필요한 프로그램을 설치하고, 이에 대한 성능 Test를 수행하였다. 성능 Test는 예보 계획을 수립할 때 WRF의 해석시간을 도출할 수 있고, 하드웨어로부터 최대 성능을 사용하고 있는지 판단할 수 있다. 하드웨어 성능 테스트를 마치고 WRF 모델의 성능을 최적화 하였다. WRF 모델은 3

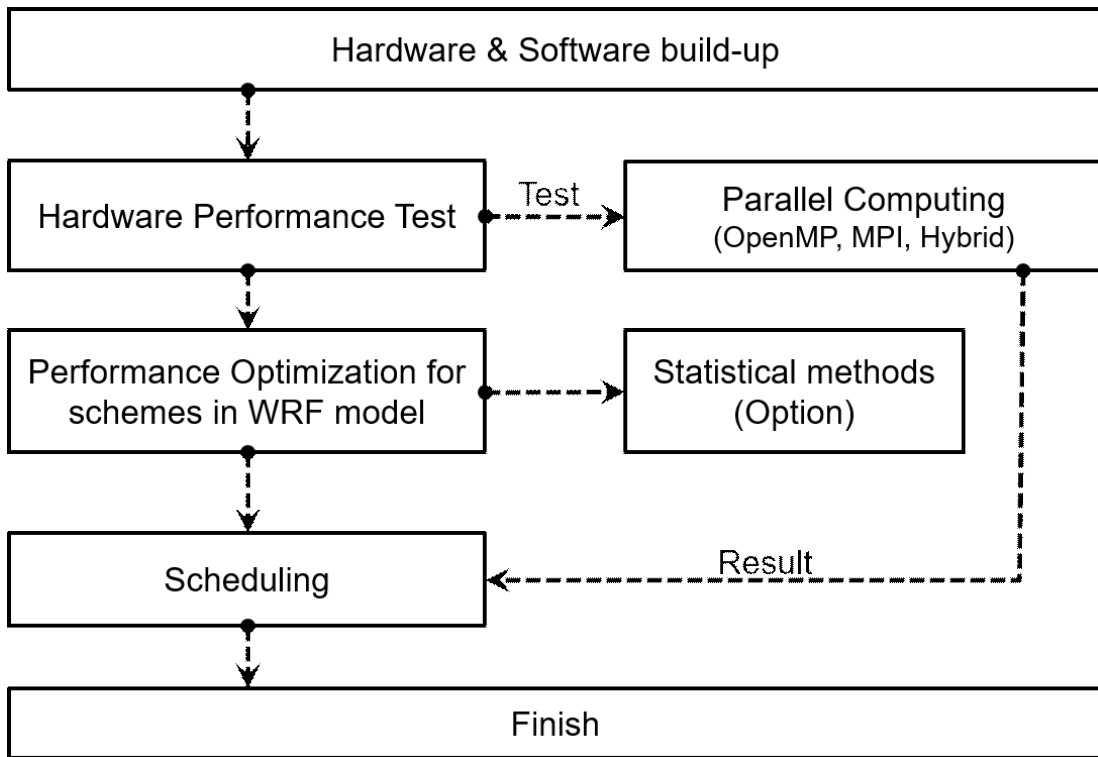


Fig. 3-7 Detailed design for real-time wind power forecasting system

장에서 언급한 대로 많은 scheme들이 존재한다. 연구사례를 통해 최적의 scheme를 선택할 수 있지만, 관측자료를 예보자료와 비교함으로써 scheme에 대한 예보 정확도를 평가할 수 있다. 본 연구에서는 LSM에 대해서 Noah LSM와 Noah-MP LSM를 행원 기상탑을 대상으로 해석하여 예보 정확도가 높은 모델을 선정했다.

성능 최적화가 끝나면 추가적인 모델 도입여부를 판단하고 모델을 선정한다. 여기에는 물리모델과 통계모델이 존재하는데, 주로 첫 번째 단계로 물리모델을 사용할 경우 통계모델을 후순위로 사용한다. 통계모델이 도입될 경우 예보 시스템은 여러 가지 모델을 통합한 Hybrid 모델로 결정되며, 통계모델을 도입하지 않을 경우 단일 WRF 모델에 의한 예보 시스템으로 분류된다. 본 연구에서는 통계모델은 도입하지 않았다. 그 대신 통계모델을 도입할 경우 주의할 점을 언급하기 위해 통계모델을 위한 전처리 과정에 대해서 언급하고자 한다.

3.2.1. 하드웨어 구축 및 성능 최적화

실시간 풍력발전량 예보 시스템을 운영할 하드웨어를 구성하였다. 하드웨어는 상업

용으로는 서버가 필요하나, 본 연구를 위해서 저예산으로 워크스테이션으로 구성하였다. CPU는 Intel(R) Xeon(R) CPU X6550 2.67GHz로 코어가 6개이고, intel사의 하이퍼스레딩(Hyper-Threading) 기술을 적용하여 총 12개이다. 메모리는 8GB로 구성되었다. 소프트웨어는 우분투 16.04 LTS이고, GNU compiler 5.4, intel compiler 12.04, netCDF 4.1.3, WPS 3.8.1, WRF 3.8.1 로 설치되었다.

WRF 모델은 계산량이 많아 고성능 연산능력이 필요한데, 이를 위한 기술이 병렬처리(Parallel Computing) 방식이다. 병렬처리 프로세스는 3가지 방법으로 분류되는데, OpenMP(Open Multi-Processing), MPI(Message Passing Interface), Hybrid(OpenMP + MPI)이다. OpenMP는 동적 메모리를 통해 연산과정 중의 결과를 서로 공유하는 방법이다. 동적 메모리를 중심으로 연산 메시지를 주고받기 때문에 단일 하드웨어 안에서만 동작이 가능하다. 또한, OpenMP는 코어별로 메모리를 구성하기 때문에 다른 병렬처리보다 많은 메모리가 필요하다.

MPI는 메시지 패킷을 생성하여 연산과정 중의 결과를 서로 공유하는 방법이다. 메시지를 생성하기 때문에 OpenMP와 달리 네트워크를 통해 이 메시지를 전달할 수 있다. 이로 인해 MPI는 다수의 컴퓨터를 내부 네트워크로 통합한 서버급에서도 동작이 가능하다. MPI는 CPU에서 메시지를 담당함으로써 CPU의 능력에 의존적이고, 서로 다른 CPU를 가진 컴퓨터로 구성할 경우 MPI의 성능은 능력이 낮은 CPU에서 연산처리가 끝날 때까지 기다리기 때문에 최하위권 CPU의 능력 이상으로 수행할 수 없다.

Hybrid 병렬연산은 OpenMP와 MPI를 결합한 병렬연산이다. 서버로 구성된 하드웨어에서 각 컴퓨터별 병렬연산은 MPI가 담당을 하고 MPI를 통해 작업량을 받은 컴퓨터는 내부 코어들에게 OpenMP 방식으로 작업량을 분할한다. MPI가 CPU 수가 늘어난 만큼 이론적으로 연산능력이 증가하지만, 실제로는 한계점이 존재하는데, hybrid 방식이 이 한계점을 보완해준다. 마찬가지로, OpenMP도 코어 수에 따라 연산능력이 이론적으로 증가하지만, 메모리 한계가 존재하고 단일 메모리에서 많은 작업을 수행할 경우 성능은 저하된다. Hybrid 방식은 이 두 방식의 단점들을 서로 보완해주는 병렬처리 방법이다.

WRF 모델에서는 3가지 병렬연산 방법을 모두 채용하고 있다. 따라서 모델 수행자가 하드웨어에 맞게 설치하여 WRF 모델을 수행하면 된다. 본 연구에서는 하드웨어 성능을 극대화하기 위해 3가지 병렬연산 모두를 검증하여 최적의 조합을 찾아냈다.

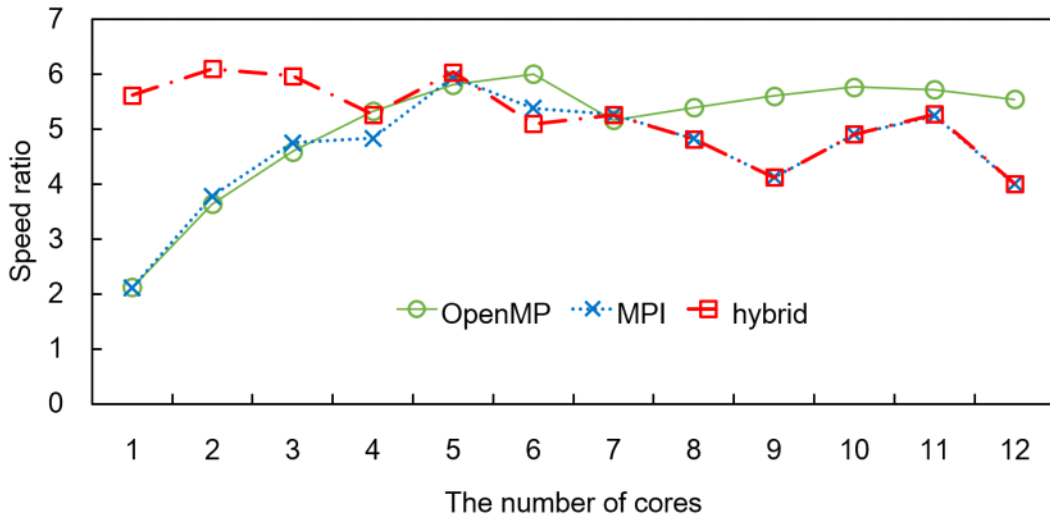


Fig. 3-8 The speed ratio of hardware performance test using three types of parallel computing.

성능을 검증하기 위한 성능지표는 speed ratio를 산출한 식(3-15)과 같다. Forecasting Time은 예보시간을 의미하고, Calculation Time은 예보시간만큼 WRF를 해석할 경우 소요되는 총 계산시간을 의미한다. 즉, speed ratio가 높을수록 소요시간대비 예보시간이 크므로 적은 시간으로 많은 예보시간을 확보할 수 있다는 의미이다.

$$Speed\ Ratio = \frac{Forecasting\ Time}{Calculation\ Time} \quad (3-15)$$

실제로 컴퓨터 공학 분야에서는 CPU의 연산속도를 평가하기 위해 부동소수점을 처리하는데 걸리는 소요시간을 산출한다. 이를 FLOP로 표현하지만, 실제로 WRF 모델에서 소요되는 시간으로 산출하기엔 어려움이 존재한다. WRF 모델은 부동소수점 연산뿐만 아니라 정수연산도 같이 존재하고 하드디스크에 입력 및 출력하는 I/O 능력도 포함되어 있기 때문이다. 즉, 식(3-15)를 통해 실제로 WRF 모델을 수행하는데 걸리는 speed ratio를 산출하여 추후 예보 시스템의 스케줄링에 참조할 수 있도록 했다.

하드웨어 성능 Test의 speed ratio 결과를 figure 3-8에 도시화하였다. 하드웨어 성능 Test를 위해 WRF 모델 구성은 개념설계 단계에서 결정된 옵션들을 선택하여 수

행하였다. 즉, figure 3-8에 도시된 결과는 상위 도메인(D01)에서부터 하위 도메인(D04)까지 수행한 결과이다.

OpenMP는 코어 수가 증가할수록 성능이 향상되었지만, 하이퍼 스레딩을 사용하는 코어 수부터는 비슷한 성능을 보여줬다. OpenMP는 하이퍼 스레딩을 사용하지 않는 코어 수 6개가 가장 높은 성능을 보여줬다.

MPI는 OpenMP와 비슷하게 코어수가 증가할수록 높은 성능을 보여줬다. 하지만, 코어 수가 6개인 시점부터 성능이 저하되는 현상을 볼 수 있다. 이는 OpenMP와 마찬가지로 하이퍼 스레딩을 사용에 의해 성능이 저하되는 것으로 볼 수 있다.

WRF에서 hybrid 방식은 먼저 MPI가 동작하고 후속으로 OpenMP가 동작한다. 예를 들어 총 12개의 코어 중에 2개를 hybrid 방식으로 수행한 경우에는 2개의 코어가 MPI 방식으로 작업량을 2등분한다. 그 다음 나머지 10개의 코어가 5개씩 그룹화 하여 각 MPI로 분할된 작업에 OpenMP 방식으로 균등하게 작업량을 재분할한다. 즉, hybrid는 MPI와 OpenMP를 동시에 사용하고 MPI에 할당된 코어의 수의 배수만큼 OpenMP가 동작하여 작업량을 재분할한다. figure 3-10에서 hybrid 방식을 살펴보면 코어 수를 1~12개까지 범위를 설정했지만, 실제로 사용된 코어는 1(12개), 2(12개), 3(12개), 4(12개), 5(10개), 6(12개), 7(7개), 8(8개), 9(9개), 10(10개), 11(11개), 12(12개)이다. Hybrid 방식에서 최대로 높은 성능을 보인 경우는 코어 2개가 MPI로 동작하고 10개의 코어가 OpenMP로 동작하는 2(12개)이다. 6개 이상은 여분의 코어가 존재하지만, 동일하게 균등분배가 불가능함으로 OpenMP가 동작하지 않았다. 이로 인해 MPI 결과와 동일한 코어 수를 사용하기 때문에 결과가 비슷했다.

병렬연산에 따라 하드웨어의 성능을 극대화했다. 최종적으로 hybrid 병렬연산으로 선택하여 MPI으로 2개의 코어를 부여하고 나머지 10개의 코어가 OpenMP 방식으로 계산을 담당하도록 구성했다. 병렬연산을 최적화해지만, 하드웨어의 성능 한계로 인해 72시간의 해석을 수행하기 위해서 12시간을 필요했다. 게다가 GFS를 받을 수 있는 시간을 고려하여 최종적으로 93시간을 예보하고 앞에 21시간은 과거자료로 버려진다.(21시간 동안의 자료는 통계모델을 통해 나머지 72시간 예보자료를 보정하는 용도로 사용할 수 있지만, 본 연구에서는 통계모델을 도입하지 않았으므로 사용하지 않았다는 의미이다.)

Figure 3-9에 예보시간에 따라 증가되는 MAE 결과를 도시화하였다. 예보시간이 지

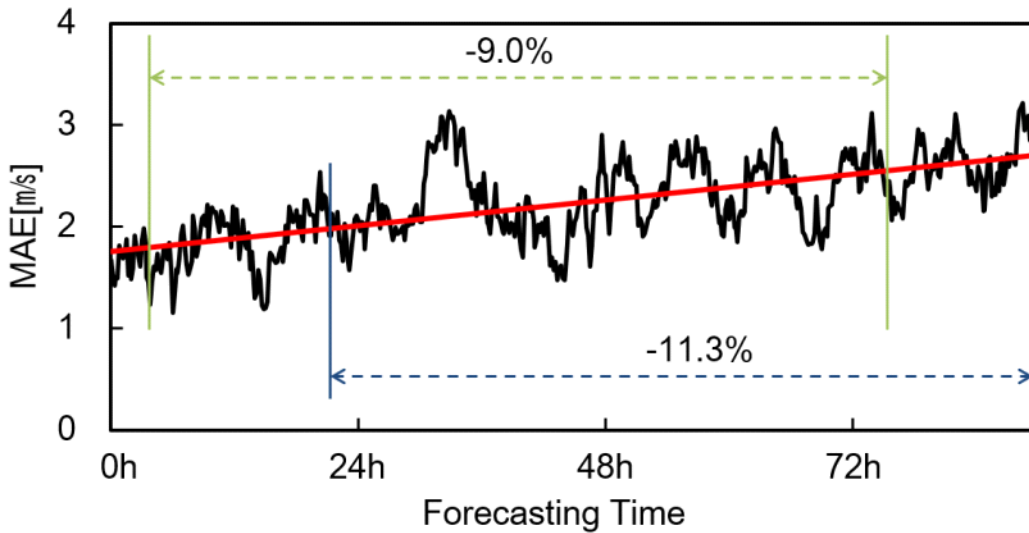


Fig. 3-9 MAE increases over forecasting time. PBias is -9.0% between 5h and 77h. PBias is -11.3% between 21h and 93h.

나갈수록 MAE가 증가하는 것을 알 수 있었다. 이는 일반적으로 기상수치모델의 오차는 예보시간이 흘러갈수록 오차가 증가하는 사실과 일치하다. 22시간에서 93시간까지의 PBias는 -11.3%로 나타났다. 하지만, 하드웨어의 성능이 우수하다면 WRF 모델이 수행하는데 걸리는 소요시간이 단축되어 최대 -9.0%까지 줄어 들 수 있다.

이처럼 하드웨어의 성능에 따라 예보 시스템이 기본적으로 내포하게 되는 오차가 존재한다. 낮은 하드웨어의 성능은 예보 시스템의 정확성에 영향을 미치므로 무시할 수 없다. 또한, 우수한 하드웨어는 WRF 모델의 소요시간을 단축시켜 작업일정을 원활하게 구성할 수 있다. 본 연구에서는 22h부터 93h에 예측된 자료를 1h부터 72h까지 예보된 자료로 정했다.

3.2.2. WRF 모델의 LSM 성능 최적화

선행연구사례를 통해 WRF 모델의 각 scheme별로 예보 정확도가 높은 scheme을 선택했지만, LSM은 Noah LSM와 Noah-MP LSM을 수행하여 예보 정확도를 평가하였다. Noah-MP LSM는 Noah LSM에서 단일 표면 온도만을 고려하는 모델을 다수의 온도들을 고려한 모델이다(Niu et al., 2011). 현실적으로는 지표면에서 발생하는 heat

flux는 기본적으로 지면표에서 방사되는 flux, 눈이 존재할 경우 눈에서 발생하는 잠열과 현열, 우거진 나무들 또는 식물들에 의해 형성된 덮개로 불리는 canopy에 의한 heat flux가 존재한다. 하지만, Noah LSM은 오직 표면 온도를 파라미터로 정의하여 지표면을 해석함으로써 현실과는 많은 차이가 존재한다. 해석하는 구역이 다양한 식물들로 구성될 경우 그 차이는 점점 커진다. 이 차이를 줄이고자 고려되지 않은 요소들을 포함한 Noah-MP LSM을 Niu et al.(2011)가 연구하였다.

Noah-MP LSM은 canopy에 의해 발생하는 heat flux와 개별로 snow modeling을 구현하여 눈의 heat flux를 구현하였다. 이로 인해 각 요소별로 표면온도들이 존재하게 되어 다수의 온도에 따른 에너지 수지(energy budget)가 정립되었다. 이는 식(3-16)과 같다. 장파 및 단파복사 scheme에서 추정된 복사열을 LSM에서 입력되고 입력된 장파 및 단파복사에 의해 발생, 흡수 작용을 적용하여 heat flux들을 계산한다. 토양은 4개의 layer로 구성되었고, 눈은 3개의 layer로 구성하여 계산된다. 또한, 대수층(aquifer)을 추가하여 빗물이 흡수 및 증발되는 현상을 구현하였다.

$$\begin{aligned}
 & SW_{dn} - SW_{up} + LW_{dn} - LW_{up} (T_{sfc}) \\
 & = SH(T_{sfc}) + LH(T_{sfc}) + G(T_{sfc})
 \end{aligned}
 \tag{3-16}$$

여기서, SW_{dn} , LW_{dn} : input shortwave and longwave radiation

SW_{up} : reflected shortwave(Albedo)

LW_{up} : upward thermal radiation

SH : sensible heat flux

LH : latent heat flux

G : heat flux

T_{sfc} : surface temperature at point

Noah LSM을 적용할 경우의 예보 정확도와 Noah-MP LSM을 적용할 경우의 예보 정확도를 상호·비교하여 우수한 예보 정확도를 도출한 LSM을 최종적으로 선택하였다. 각 scheme마다 예보 정확도를 평가하여 해석하고자 하는 영역에 최적화된




Fig. 3-11 Model structural difference between Noah LSM and Noah-MP LSM. Canopy temperature(T_{can}), snow temperature(T_{snow}), bare ground temperature(T_{bc}), surface temperature(T_{skin}), vegetated ground temperature(T_g)




Fig. 3-10 Surface energy budget of Noah-MP LSM from eq. 2

scheme들을 선정할 수 있다. 하지만, 분석하는데 많은 소요시간과 노력이 필요하므로 선행연구사례를 검토하는 것이 합리적일 수 있다.

풍력분야는 기상분야와 달리 상층기류보다는 풍력터빈의 허브높이와 비슷한 하층기류에 관심이 있다. 하층기류는 지표면에서 발생하는 복사열의 흡수 및 방출이 중요하고, 이를 담당하는 LSM의 선택이 중요하다고 할 수 있다. 본 연구에서는 LSM에 대해 예보 정확도를 평가하여 우수한 모델을 선정하고자 한다. 후보 모델은 Noah LSM와 Noah-MP LSM이다.

Figure 3-12은 LSM를 Noah로 수행했을 때 MAE와 Noah-MP로 수행했을 때 MAE를 나타내고 있다. Noah-MP가 전체 예보시간에 대해서 Noah보다 정확도가 높았다. 특히 12h 이후에 Noah LSM가 높은 오차를 보였던 현상이 Noah-MP에서는 감소된 현상을 알 수 있었다.

Noah는 -11.3%로 과소 예측을 나타냈고 MAE는 2.36 m/s, RMSE는 3.04 m/s, NRMSE는 12.6%, IOA는 0.88로 나타났다.(table 3-6) 반면에 Noah-MP는 2.5% 증가하여 -8.8%로 과소 예측을 나타냈고 MAE는 0.23 m/s 감소한 2.13 m/s, RMSE는 0.31 m/s 감소한 2.73 m/s, NRMSE는 1.3% 감소한 11.3%, IOA는 0.02 증가한 0.9로 나타났다. 모든 통계량이 동시에 증가하여 Noah LSM보다는 Noah-MP가 예보 정확도에 우수함을 나타내고 있었다.

장기예보에서도 Noah와 Noah-MP의 예보 정확도를 살펴보면(figure 3-13) 대체로 Noah보다는 낮은 오차를 보여주고 있다. 특히 4일 예보까지가 낮은 오차를 보여줬다. 5일 예보 후부터는 Noah와 Noah-MP의 결과가 급격하게 증가하는 추세를 보여주고 8일 예보 후로는 오차가 변동하는 현상을 보여줬다. Noah LSM의 전체 MAE의 평균은 2.68 m/s 이고, Noah-MP LSM의 전체 MAE의 평균은 2.54 m/s이다. Noah-MP LSM이 Noah LSM보다 0.14 m/s 우수한 것으로 나타났다.

특정 예보시점을 기준으로 오차가 급격하게 변화하는 현상이 발견되었다. 이는 풍속뿐만이 아니라 다른 기상요소에서도 발견될 것으로 생각되어 다음으로 지표면 모델과 연관된 온도 및 압력 예보 정확도를 살펴봤다.(figure 3-14, 3-15)

Noah-MP는 온도 예측 결과는 Noah보다는 전체적으로 정확도가 높았다.(figure 3-14) 특히 1일부터 4일까지 급격하게 정확성이 증가됨을 확인할 수 있었다. 이는 Noah-MP가 Noah보다 초반 온도예측을 잘 추정한다고 볼 수 있다. 그리고 예보 초반

에 낮은 오차로 인해 중반 시점에서의 온도 예보도 Noah보다 높음을 확인할 수 있다. 하지만 후반에 온도 예보는 Noah와 Noah-MP LSM 모두 높은 오차를 나타내었고 장기적인 측면에서는 뚜렷한 향상은 없었다.

반면에 압력 예보는 Noah LSM가 Noah-MP LSM보다 전체적으로 정확도가 높았다 (figure 3-15). 오차 경향은 Noah와 Noah-MP 모두 전체적으로 비슷한 경향을 보여줬다. 이로 인해 압력에 의한 풍속변화보다는 온도에 의한 풍속변화가 존재했다고 볼 수 있고, 지표면에서 온도상승에 의해 발생하는 상승기류와 온도하락에 의해 발생하는 하강기류를 압력예측보다 좀 더 정확하게 해석했다고 판단된다.




Fig. 3-12 Forecast error of WRF model with Noah LSM and Noah-MP LSM in medium-term.

Table 3-6 Forecasting error depends on LSM(Noah, Noah-MP) in medium-term.

Surface Model	Noah	Noah-MP
MAE[m/s]	2.36	2.13(-0.23)
RMSE[m/s]	3.04	2.73(-0.31)
IOA	0.88	0.90(+0.02)
PBias[%]	-11.3	-8.8(+2.5)
NRMSE[%]	12.6	11.3(-1.3)

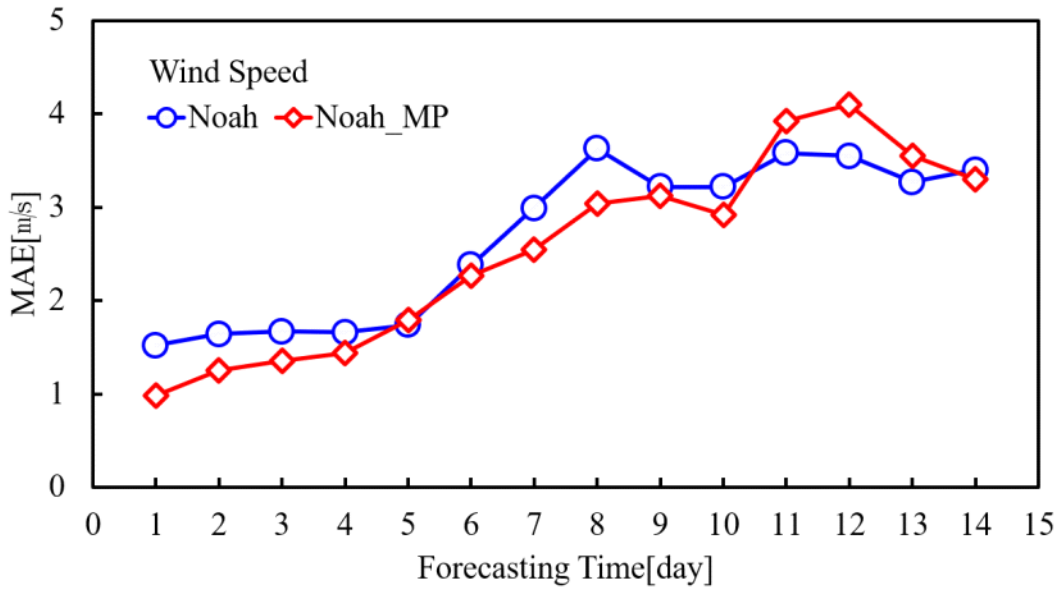


Fig. 3-13 Forecast error of wind speed in the WRF model with Noah LSM and Noah-MP LSM in long-term.

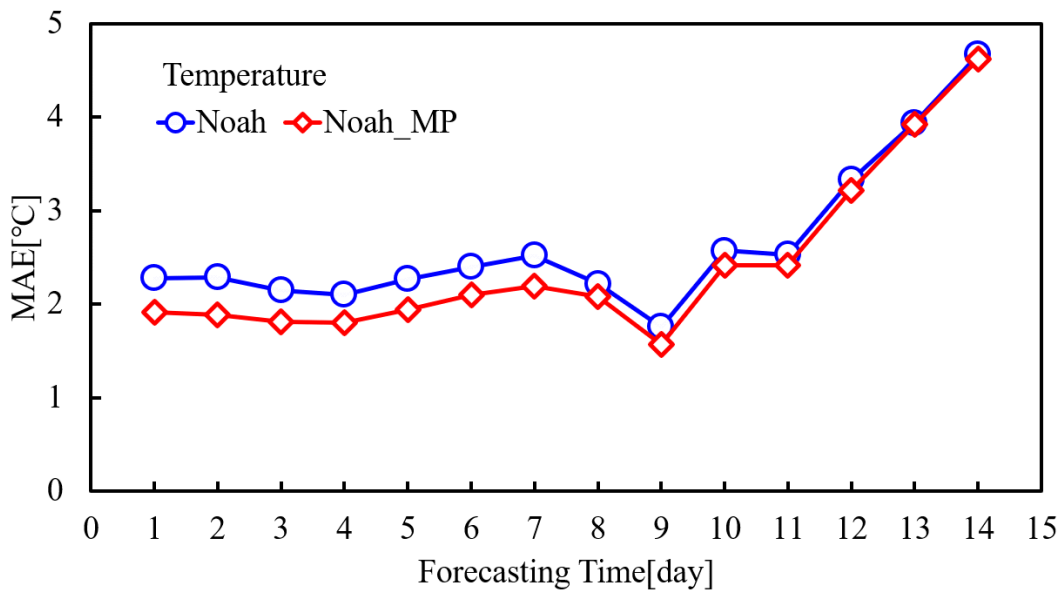


Fig. 3-14 Forecast error of temperature in the WRF model with Noah LSM and Noah-MP LSM in long-term.




Fig. 3-15 Forecast error of pressure in the WRF model with Noah LSM and Noah-MP LSM in long-term.

3.2.3. 예보 시스템 scheduling

결정된 수행절차를 바탕으로 작업일정을 수립하고자 한다. 작업일정은 예보 수행시점, 예보시간, WRF 모델의 소요시간, 자료 제출시간을 고려하여 계획해야 한다. Figure 3-16에 실시간 풍력발전량 중기예보 시스템에 대해서 작업일정을 구성하였다. 자료 제출시간은 각 예보 목적에 따라 달라질 수 있는데 본 연구에서는 자정 0시로 정하여 자정 0시를 예보자료를 제공하는 시작시점과 동일하게 정했다. 자정 0시로 정하면 하루 24시간 기준이 일상생활과 동일하게 되어 예보 시점과 현재 시점이 같아 혼동을 줄일 수 있다.

WRF 모델의 소요시간은 “3.2.1 하드웨어 구축 및 성능 최적화” 에서 결과로 도출한(figure 3-10) speed ratio를 사용하여 산정할 수 있다. speed ratio가 약 6으로 도출되었으므로 중기예보 72시간을 수행할 경우 12시간이 소요된다. 이로 인해 최소 정오 12시 이전에 WRF 모델이 수행되어야 한다.

GFS 데이터는 00UTC, 06UTC, 12UTC, 18UTC에 자료를 수집되어 기상수치모델을

수행한 다음 자료를 제공한다. GFS 데이터가 기상수치모델이 수행되고 결과가 도출되어 업로드(upload)되는데 걸리는 소요시간은 총 4~5시간 정도 소요된다. 소요시간은 자료의 수집 및 해석시간 편차, 인터넷 속도 등에 의해 달라진다. UTC는 한국시간과 9시간 차이이므로 03KST(18UTC), 09KST(00UTC), 15KST(06UTC), 21KST(12UTC)와 같다. 이로 인해 00UTC는 정오 12시 이후에 가능하므로 00UTC 이전인 18UTC 자료를 사용하여 WRF 모델을 수행해야 자정 12시에 예보자료를 제공할 수 있다.

18UTC 자료를 선택함으로써 추가로 WRF 모델을 수행하는 시간은 21시간이다. 중기예보의 72시간과 추가시간인 21시간을 합치면 총 93시간이다. 21시간은 예보 도출 시점이 자정 0시임을 고려하면 사용할 수 없는 예보자료이다. 이는 하드웨어의 성능 한계로 인해 발생하는 쓰레기 자료이고, 하드웨어의 성능향상으로 인해 줄여들 수 있다. 계획된 일정을 기반으로 Test를 수행하여 자정 0시에 예보자료가 도출되는데 확인하였다.

최종적으로 계획된 작업일정을 figure 3-17에 도시화 하였다. 작업일정대로 Test를 한 결과 GFS 데이터를 인터넷으로 받는데 약 30분정도 소요가 되었고, WPS는 30분, WRF 모델은 15.5시간 후처리는 30분정도 소요되었다. 이로 인해 오전 7시에 수행된 예보 시스템은 자정 0시에 자료를 도출할 수 있었다. 각 소요시간은 최대로 소요되는 시간으로 고려되었다. 즉, 실제로 운영할 때는 자정 0시 이전에 자료가 도출되었다.

장기예보는 2주일인 14일을 예보하기 위해서는 56시간이 필요하다. 즉, 장기예보는 3일 1번 예보가 가능했다. 본 작업일정은 하루에 1번 제공을 목적으로 두고 있으므로, WRF 모델의 수행시간을 감소해야 한다. 이를 위해서는 계산시간을 가장 많이 차지하고 있는 downscaling 기법에서 수평해상도를 변경하여 계산시간을 줄였다. 중기예보는 상세한 예보정확도를 위해 0.9 km를 선택했지만, 장기예보는 일단위를 선택하고 있고, 예상 발전량의 추세를 보아 장기적인 계획의 초안을 목적으로 볼 수 있다. 그러므로 장기예보는 8.1 km까지 해석을 수행하였다. 이를 통해 WRF 모델의 소요시간을 2주일 예보를 기준으로 3.5시간까지 단축시켰다.




Fig. 3-16 Scheduling for medium-term wind power forecasting system considering the time required to run WRF model and download GFS data.

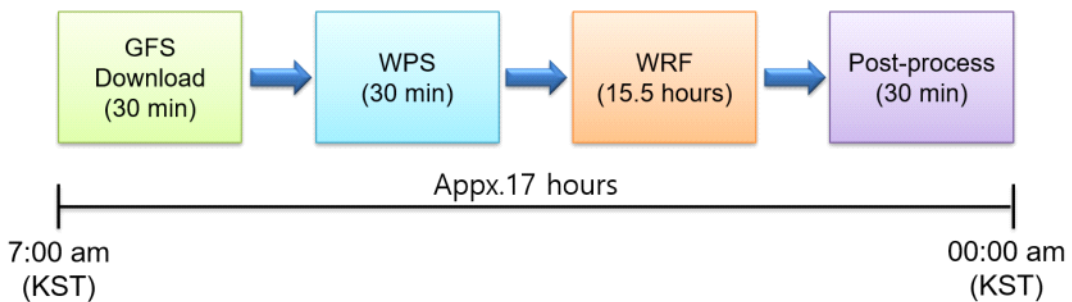


Fig. 3-17 Final forecasting schedule in medium-term wind power forecasting system.

3.3. 통계모델을 위한 UV method

기상수치모델을 이용하여 예보한 풍속을 정확도 향상을 목적으로 통계모델을 도입한다. 통계 모델은 시간 도메인에서 시간 흐름에 따른 통계량 변화, 추세 등을 파악하여 한 단계 앞(one step-ahead)을 추정하게 된다. 또는 신경망 모델과 같이 다량의 자료를 입력하여 알고리즘을 학습하는 모델도 존재한다(Aguera-Perez et al., 2018). 이와 같은 통계모델들은 추정하고자 하는 요소를 기준으로 주변 환경변수 또는 독립 변수들을 선정하여 모델에 사용한다.

풍력 발전량 예보 시스템에서 사용되는 주 변수는 풍속이다. 기상수치모델에서 예보된 풍속을 기반으로 통계모델을 통해 풍속을 보정한 다음 최종적으로 W2P(wind-to-power) 모델을 통해 풍력터빈의 출력량을 예보한다.(W2P 모델은 풍속을 출력으로 전환해주는 모델을 의미한다.) 하지만, 풍속자료만 사용해서는 예보 정확도를 향상시키기엔 한계가 존재하여 풍향, 온도, 습도, 압력, 지형, 위치 등을 추가로 고려한다.

풍속, 풍향, 온도 등 통계모델에서 사용되는 다양한 변수들은 서로 단위가 다르다. 특히 풍속은 m/s 단위이고, 풍향은 육십분법으로 나타나기 때문에 두 변수들의 단위 차이에 의한 정규화가 필요하다. 또한, 풍속은 직교좌표계로 표현이 하지만, 풍향은 육십분법 또는 호도법으로 표현할 경우 구좌표계로 표현하여 풍속과 달리 수치적인 높고 낮음을 나타내지 않고 방향성만을 표현하는 요소이다. 즉, 풍향은 다른 변수들과 달리 그 성질과 특성이 다른 변수이다.

Figure 3-18는 풍향을 평균할 경우 발생하는 오류를 보여주고 있다. 예를 들어 풍향 값이 45° 와 315° 을 평균할 경우 $(45^\circ + 315^\circ) \div 2 = 270^\circ$ 로 산출된다(figure 3-18(a)). 하지만, 풍향의 참값은 방향성을 고려하여 0° 가 나와야 한다(figure 3-18(b)). 참값인 0° 가 나오도록 산출하기 위해서는 figure 3-18(c)에서 보이듯이 2개의 풍속을 각각 x방향과 y방향 성분으로 분해하여 u-speed, v-speed를 산출한다. 산출된 x방향 성분인 u-speed의 평균과 y방향 성분인 v-speed의 평균을 산출하여 평균




Fig. 3-18 Error of the case of averaged wind direction (a) averaged wind direction in degree, (b) the true value of averaged wind direction, (c) averaged wind direction using u-speed and v-speed

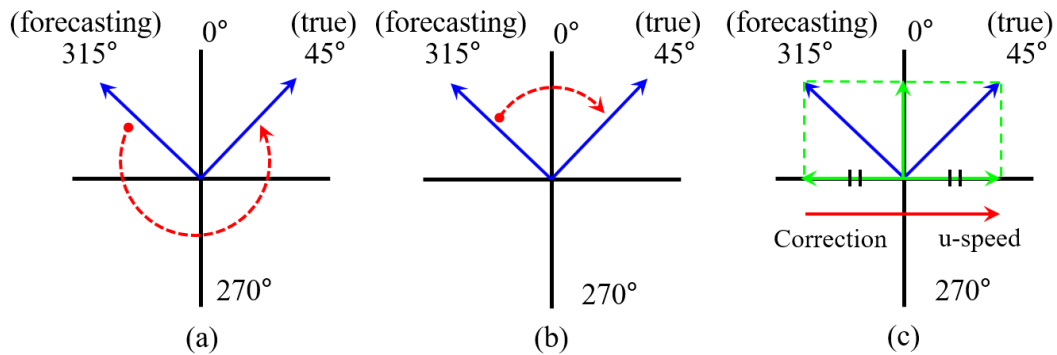


Fig. 3-19 Error of the case of corrected wind direction (a) the correction to wrong way, (b) the correction of right way, (c) corrected wind direction using u-speed and v-speed

된 u-speed와 v-speed의 벡터 합을 구하면 figure 3-18(c)에서 보이듯이 x방향 성분은 서로 상쇄되고 y방향 성분만 남은 풍향이 도출하게 된다. 이 값이 구하고자 하는 참값인 0°가 된다.

이와 마찬가지로 풍향을 보정할 때도 동일한 현상이 발생한다(figure 3-19). 앞서 언급한 예시와 동일하게 45°를 실측된 풍향 데이터이고, 315°를 예보된 풍향 데이터라고 가정했다. 예보된 풍향 데이터 315°를 실측된 풍향 데이터 45°로 보정하면, 수치적으로 인해 -270°만큼 보정을 수행하게 된다(figure 3-19(a)). 하지만, 이상적인

상황은 315° 에서 +90° 만큼 보정되어 시계방향으로 보정되는 상황이다(figure 3-10(b)). 따라서 figure 3-18(c)와 동일하게 풍향데이터를 u-speed와 v-speed로 분해한 다음 v-speed는 동일한 값을 나타내고 있으므로 보정을 수행하지 않고, u-speed만 보정을 수행하여 참값인 45° 로 보정되는 방법이 합리적이라고 생각된다.

이와 같이 통계모델로 풍향을 보정하면 참값의 반대방향으로 보정이 되는 경우가 발생한다. 이 문제를 해결하기 위해 앞에서 언급한 대로 x방향 성분과 y방향 성분으로 분해하여 각 같은 성분별로 보정을 한 후 합성을 해야 한다. 이를 본 연구에서는 UV법으로 정의하였다.

UV법을 사용하기 위해 x방향 성분, y방향 성분으로 분해하기 위해 사용된 수식은 식 (3-17, 3-18)와 같다. spd는 풍속이고, u는 x방향 성분, v는 y방향 성분을 의미한다. (3-17~20)식은 0° 를 북쪽으로 기준하여 산출되는 식이다. 식(3-19)은 u-speed와

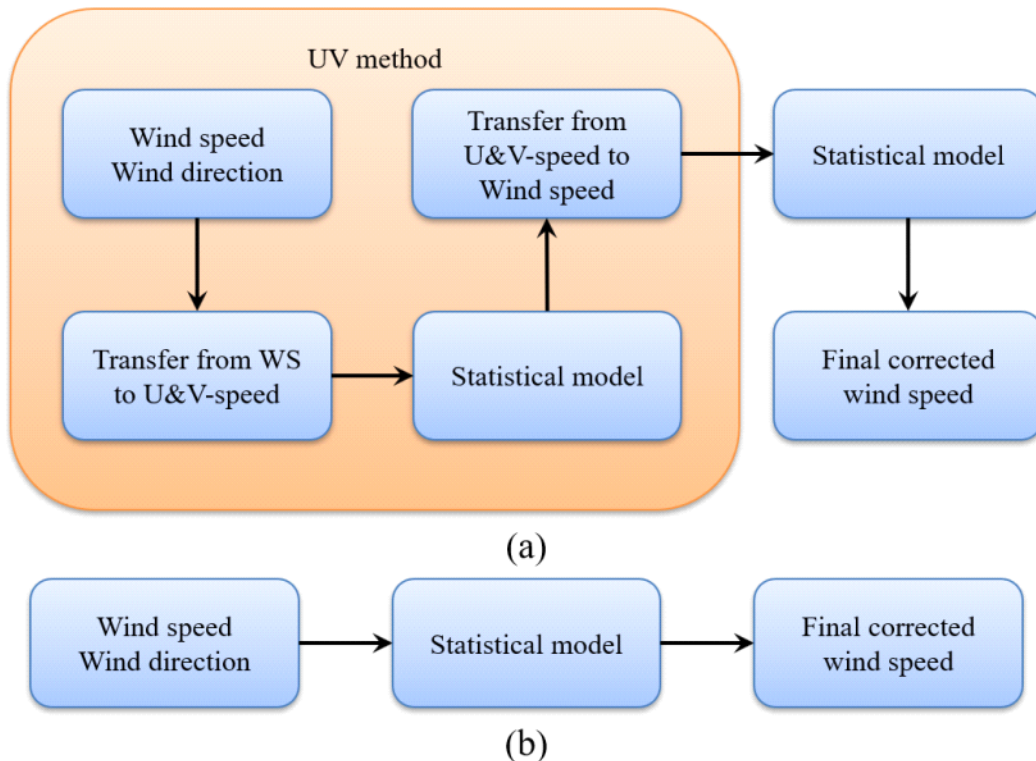


Fig. 3-20 The processing of applying a statistical model with UV method(a) and without UV method(b).

v-speed를 사용하여 풍속을 산출하는 식이고, 식(3-20)은 풍향을 산출하는 식이다. 식(3-20)의 단위는 육십분법 나타난다.

$$u = -spd \times \sin\theta \quad (3-17)$$

$$v = -spd \times \cos\theta \quad (3-18)$$

$$SPD = \sqrt{u^2 + v^2} \quad (3-19)$$

$$WDIR \equiv (270 - \text{atan}(v/u) \times 180/\pi) \pmod{360} \quad (3-20)$$

UV법을 적용하기 전·후를 비교하기 위해 UV법을 적용하여 통계모델을 사용한 결과와 UV법을 적용하지 않은 동일한 통계모델을 사용한 결과를 서로 비교하였다. 사용된 통계모델은 시계열 분석에서 기초적으로 채용되는 선형회귀법을 사용하였고, 학습 알고리즘에서 보편적으로 사용되는 신경망 모델을 사용하였다.

Figure 3-20은 UV법을 적용한 경우와 미적용된 경우의 절차를 보여주고 있다. UV법을 적용하지 않을 경우에는 풍속과 풍향을 본연의 단위를 유지한 채 통계모델에 입력이 된다. 회귀모델은 풍향 자료를 사용하지 않았고, 오직 풍속 자료만 사용하여 결과를 도출하였다. 신경망 모델은 풍속 및 풍향자료를 사용하여 결과를 도출하였다. 신경망 모델은 모델의 우수성을 입증하는데 목적을 두지 않았고, UV법의 적용 전·후를 비교함에 목적이 있으므로, 신경망 모델의 최적화는 수행하지 않았다. 즉, 신경망 모델은 기본적으로 구조에 따라 성능이 차이가 존재하지만, 본 연구에서는 2×4×2 구조로 고정하여 수행하였다.

UV법을 도입할 경우 풍속 및 풍향자료를 u-speed, v-speed로 분해 한 다음에 통계모델에 입력하여 학습을 시작했다. 각 통계모델에서 도출되는 값은 u-speed와 v-speed이고, 최종 결과물은 식(3-19, 3-20)을 이용하여 풍속 및 풍향을 산출하였다.

여기서 사용된 풍속 및 풍향자료는 행원기상탑에서 측정된 80 m자료를 사용하였다. 통계모델에서 훈련용으로 사용된 자료의 기간은 2018. 1. 1 ~ 1. 17까지이고, 검증용으로 사용된 자료의 기간은 2018. 1. 18 ~ 1. 31까지이다.

첫 번째로 선형회귀법으로 풍속과 풍향을 사용하여 최소제곱법(Least square method)을 적용해 보았다. 풍속과 풍향을 독립변수로 하고 종속변수로 풍속을 정의하

Table 3-7 MAE and RMSE using regression model with UV method and without UV method.

Order	UV method	MAE	RMSE
Linear ($y = ax + b$)	Before	1.91	2.53
	After	1.99	2.64
Quadratic ($y = ax^2 + bx + c$)	Before	1.90	2.52
	After	1.85	2.48
Cubic ($y = ax^3 + bx^2 + cx + d$)	Before	1.90	2.51
	After	1.85	2.48

는 수식을 최소제곱법을 통해 각 계수들을 구하였고 식(4-1)와 같다. 풍향이 풍속에 비해 수치적으로 높기 때문에 풍향의 계수가 풍속의 계수보다 상대적으로 작게 추정되었다. 식(3-21)을 통해 보정된 결과는 MAE를 기준으로 1.87 m/s, RMSE를 기준으로 2.47 m/s가 나왔다. 이는 식(3-21)을 통해 보정하기 전의 결과를 보면, MAE를 기준으로 1.99 m/s이고, RMSE는 2.60 m/s로 오차가 감소하는 현상을 볼 수 있었다.

$$ws = -0.795544 + 0.994322ws + 0.006079wd \quad (3-21)$$

Table 3-7는 회귀모델을 사용하여 1차부터 3차 다항식까지 확대하여 결과를 도출하였다. 또한, UV법을 사용하여 풍속과 풍향을 u-speed와 v-speed로 분해한 다음 회귀모델을 동일한 모델에 적합하여 보정된 풍속을 도출하였다. 이는 figure 3-20에서 도시화된 절차와 같다.

UV법을 미적용한 1차 회귀모델의 결과는 MAE가 1.91 m/s, RMSE가 2.53 m/s로 나타났으며, 2차 회귀모델의 결과는 MAE가 1.90 m/s, RMSE가 2.52 m/s로 나타났고, 3차 회귀모델의 결과는 MAE가 1.90 m/s, RMSE가 2.51 m/s로 차수가 증가할수록 오차의 감소율은 점차 줄어들었다. 이는 차수에 상관없이 회귀모델의 평균값에 집중하는 현상으로 볼 수 있고 회귀모델의 한계점을 보여준 결과이다.

UV법을 적용한 1차 회귀모델의 결과는 MAE가 1.99 m/s, RMSE가 2.64 m/s로 증가하였으나, 2차 회귀모델에서는 MAE가 1.85 m/s, RMSE가 2.48 m/s로 감소하는 현상이 나타났다. 3차 회귀모델에서는 MAE가 1.85 m/s, RMSE가 2.48 m/s로 2차 회귀모델과 같은 결과를 도출하였는데, 이는 UV법을 통해 분해된 예보된 u-speed & v-speed와 측정된 u-speed & v-speed의 관계가 2차 방정식의 형태에 가까운 패턴을 보여줬기 때문이다. 즉, UV법을 도입하기 전인 풍속 및 풍향은 1차 방정식을 제외하고 관계성을 정립하지 못하였지만, UV법을 도입하여 새로운 풍속과 풍향의 관계성을 발견했다고 볼 수 있다.

회귀모델을 통해서는 완벽하게 동일한 조건에서 UV법 적용 전·후의 차이를 발견하지 못했다. 이는 회귀식이 출력변수가 하나의 변수로만 구성되기 때문이다. UV법을 이용할 경우 출력 변수로 u-speed & v-speed의 2개의 독립변수로 나와야 동일한 조건에서의 UV법 적용 전·후를 비교할 수 있기 때문이다. 하지만, Table 9의 결과를 통해 회귀모델의 한계점을 알 수 있었고, 풍속과 풍향의 관계가 1차 방정식이외에는 정확도 향상이 나타나지 않았지만, UV법을 통해 u-speed & v-speed로 분해를 한 경우에는 2차 방정식으로 데이터의 관계성을 찾게 되었다.

동일한 조건과 모델에서 사용하기 위해서 신경망(Neural network) 모델을 도입하여 UV법 적용 전·후의 차이를 살펴보았다. 신경망 모델은 입력층, 은닉층, 출력층의 구조에 따라 성능이 달라진다. 본 연구에서는 구조에 따른 차이를 제거하기 위해서 입력층 2개, 은닉층 4개, 출력층 2개로 구성하여 실험조건을 같게 하였다.

훈련이 완료된 신경망 모델은 figure 3-21와 figure 3-22과 같다. figure 3-21은 풍속과 풍향 데이터를 사용한 모델이고 이를 NN(WSWD) 모델로 부르겠다. figure 3-22은 u-speed와 v-speed를 사용한 모델이고 이를 NN(UV) 모델로 부르겠다. 두 모델은 출력층을 2개로 구성하여 NN(WSWD)는 풍속과 풍향이 도출되는 모델이고, NN(UV)는 u-speed와 v-speed가 도출되는 모델이다. NN(WSWD)에 입력되는 풍속 데이터는 30 m/s로 나눠줘 0부터 1사이인 값으로 축소하였다. 또한 풍향 데이터를 360° 로 나눠줘 0부터 1사이인 값으로 축소하였다. 반면에 NN(UV) 모델에 입력되는 u-speed & v-speed는 동일한 차원을 가지고 있으므로 scaling 조절은 하지 않았다.

Table 3-8에 NN(WSWD) 모델과 NN(UV) 모델에 의해 보정된 풍속 및 풍향에 대한 정확도 결과를 정리하였다. 풍속에 대한 정확도 결과에서 NN(WSWD)는 PBias가 0.5%




Fig. 3-21 the structure of a neural network using wind speed and wind direction.




Fig. 3-22 the structure of a neural network using u-speed and v-speed.

Table 3-8 Comparison of measured data and predicted data using neural network models. NN(WSWD) used variables of wind speed and wind direction. NN(UV) used variables of u-speed and v-speed. ()* means the difference between neural network models and the predicted data form WRF.

Wind Speed			
Statistical measures	WRF	WRF + NN	
		NN(WS,WD)	NN(U,V)
MAE	1.99	1.71(-0.28)	2.05(+0.06)
RMSE	2.60	2.37(-0.23)	2.59(-0.01)
PBias	10.10	0.50(-9.60)	10.90(+0.80)
IOA	0.85	0.88(+0.03)	0.88(+0.03)
R	0.76	0.79(+0.03)	0.80(+0.04)
NRMSE	15.1	15.3(+0.2)	14.7(-0.04)

Wind Direction			
Statistical measures	WRF	WRF + NN	
		NN(WS,WD)	NN(U,V)
MAE	43.19	43.32(+0.12)	30.39(-12.80)
RMSE	85.92	70.90(-15.02)	68.68(17.24)
PBias	0.20	3.20(+3.00)	-4.30(-4.50)
IOA	0.74	0.75(+0.01)	0.77(+0.03)
R	0.56	0.65(+0.09)	0.68(+0.12)
NRMSE	23.9	19.4(-4.50)	19.4(-4.50)

로 9.6%만큼 감소했으나, MAE와 RMSE를 살펴보면 1.71 m/s, 2.37 m/s로 약 0.2 m/s만큼 감소하여 미미한 정확도 향상을 보여줬다. IOA와 피어스 상관관계수(R)은 0.88, 0.79로 0.03만큼 증가하였다. 반면에 UV법이 적용된 NN(UV) 모델은 PBias가 0.08만큼 증가하여 MAE도 0.06 m/s만큼 동시에 증가하였다. RMSE는 2.59 m/s로 0.01 m/s의 차이만 있을 뿐 거의 변동이 없다고 볼 수 있다. 하지만, IOA와 R값이 0.88과 0.80으로 증가하여 측정된 값과 예보된 값의 경향성은 비슷하게 변경된 것으로 판단된다. 즉, 수치적으로는 편차가 줄어들지는 않았지만, 측정자료의 변화추세에 따라 예보자료가 변경되었음을 의미한다.

풍향 데이터의 정확도 결과를 살펴보면 NN(WSWD) 모델은 PBias가 3.20%로 3% 증가하였고, MAE는 43.32°로 0.12° 증가하였다(table 3-8). 반면에 RMSE는 70.90°로 15.02°만큼 감소하여 평균적인 오차는 소량 증가했지만, 급격한 오차는 다소 감소하였다. IOA와 R은 0.75, 0.65로 향상되었다. 반면에 NN(UV) 모델은 PBias가 4.30%로 4.50% 감소하였고, MAE는 30.39°로 12.80°만큼 감소하여 전체적인 오차는 감소하였으나, RMSE가 68.68°로 17.24°만큼 증가하여 편차가 큰 오차가 다소 증가하였다. 그러나, NN(UV) 모델은 IOA와 R의 평가에서 NN(WSWD) 모델에 비해 높은 정확도를 보여줬다.

이상과 같이 풍속의 정확도는 UV법을 적용한 NN(UV) 모델이 NN(WSWD) 모델보다 다소 낮았고, 데이터의 일치도(IOA)는 동일한 수준으로 보여줬다. 이는 NN(WSWD)는 수치적으로 감소되는 방향으로 보정되는 모델을 의미하고, NN(UV)는 u-speed와 v-speed의 관계성을 해석하여 다소 편차는 증가했지만, 풍속이 시간흐름에 따라 변동하는 경향성을 추적할 수 있도록 보정하는 모델로 볼 수 있다.

여기서, 사용된 신경망 모델은 최적화가 수행되지 않았다. 신경망 모델의 최적화란 신경망 모델의 구조를 의미하며 입력층, 은닉층, 출력층의 개수, 학습율, 활성화함수 등이 포함된다. NN(WSWD)와 NN(UV)모델은 동일한 조건하에서 UV법을 적용한 전·후의 상태 차이를 알고자 했다. 따라서 table 3-8의 결과는 최적화를 수행한다면 정확도를 높일 수 있다.

Figure 3-23은 측정된 풍향 데이터와 WRF 모델에서 예보된 풍향데이터를 보여주고 있다. 300°에서 360° 사이에 많은 데이터가 집중되어있고, 일부 200°에서 360°로 예보되었지만, 실제로는 0°에서 50° 사이에 측정된 결과를 볼 수 있다. 또한,

WRF 모델에서는 50° 이하로 예보했지만, 실제로는 300° 에서 360° 로 측정된 데이터를 볼 수 있다.

Figure 3-23에서 빨간색 박스 데이터 그룹은 WRF 모델에서 예보된 풍향 데이터 중 0° 에서 50° 사이에 존재하는 데이터와 측정된 풍향데이터의 180° 이하의 데이터를 표시하였다. 파란색 박스 데이터 그룹은 측정된 풍향데이터의 180° 이상의 데이터를 표시하였다. 빨간색 박스 데이터 그룹은 WRF 모델에서 측정 데이터를 잘 추정한 그룹이다. 파란색 박스 데이터 그룹은 평균적으로 약 40° 만큼 오차를 보이는 그룹으로 0° 에서 50° 부근으로 예보되었지만, 실제로는 300° 에서 360° 부근으로 측정된 데이터가 존재하는 그룹이다. 즉, 신경망 모델을 사용할 경우 파란색 박스 데이터 그룹인 WRF 모델에서 예보된 값들은 보정되어서 300° 에서 360° 부근으로 조정되어야 하는 상황이다.

이들 데이터 그룹이 NN(WSWD) 모델과 NN(UV) 모델을 통해서 어떻게 값이 변하는지 살펴보았다. NN(WSWD) 모델을 사용하여 변경된 데이터는 figure 3-24에 도시화하였고, NN(UV) 모델을 사용하여 변경된 데이터는 figure 3-25에 도시화하였다.

NN(WSWD) 모델은 풍향 데이터가 분포되어 있는 현상을 특정 값에 집중된 형태로 변화시킨 결과를 볼 수 있다. $150^\circ \sim 200^\circ$ 와 300° 부근에 예보된 값들이 집중되었다. figure 3-23에서 나타난 50° 이하인 풍향 데이터는 NN(WSWD) 모델을 통해 0° 부터 270° 까지 넓게 분포되었고 특히 200° 부근에 집중되었다. 이를 통해 NN(WSWD)는 table 3-8에서 보여 듯이 풍속의 정확도는 높았으나, 풍향 데이터는 실측값에 가까운 시계반대 방향으로 풍향데이터를 조정하지 않고, 오직 수치적으로만 계산하여 시계 방향으로 풍향 데이터를 조정되었다.

이는 풍속의 정확도 향상을 위해서 풍향 데이터를 NN(WSWD) 모델에 입력하여 높은 정확도를 확보했지만, 실제로는 풍향 데이터의 오차를 증가시키게 되었다. 또한, 풍향 데이터가 이상적인 방향성을 고려하지 못하고 오직 수치적으로 편차를 계산해서 그 편차를 줄이고자 하는 역할만 수행하였다.

NN(UV) 모델에서 WRF 모델에서 예보된 데이터를 보정한 결과를 살펴보면, 전체적으로 데이터가 산포되어 있고 일부 실측 데이터가 집중되어 있는 값으로 집중되었다 (figure 3-25). 파란색 데이터 그룹이 보정된 결과를 살펴보면 NN(WSWD) 모델과 달리 200° 부근에는 데이터가 존재하지 않고 실측값인 300° 에서 360° 부근으로 데이

터가 조정되었다. 빨간색 데이터 그룹을 살펴보면 실측값과 상이한 값으로 보정된 데이터도 일부 존재했다. 하지만, NN(UV) 모델은 수치적으로 계산을 수행하지만, 풍속과 풍향을 u-speed와 v-speed로 분해하여 보정하기 때문에 자연스럽게 방향성도 같이 보정된 것으로 볼 수 있다. 즉, NN(UV) 모델은 예보된 풍향 데이터를 측정된 풍향 데이터와 비교하여 최단거리를 찾아 보정한다고 볼 수 있다.

NN(WSWD) 모델은 풍속 정확도는 높았지만, NN(UV) 모델처럼 풍향 데이터를 알맞은 방향으로 보정하지 못했다. 따라서 알맞은 보정을 위해서는 신경망 모델과 같은 통계모델을 도입할 때는 UV법을 사용하여 데이터를 정제한 후 사용해야 한다고 생각한다.

상기 언급한 데이터들을 바람장미로 표현하였다(figure 3-26). 측정 데이터는 주풍향이 337.5°로 전체 데이터의 47%를 차지하고 있다. WRF 데이터는 주풍향이 337.5°로 전체 데이터의 37%를 차지하고 있다. WRF 모델이 주풍향을 잘 예측하고 있으나, 빈도수는 10% 낮은 빈도수를 보여줬다. 즉, 경향성은 잘 나타내고 있으나, 일부 데이터가 오차를 보유하고 있음을 알 수 있다.

NN(WSWD) 모델을 이용하여 WRF 모델의 데이터를 보정한 결과는 주풍향이 315°로 전체 데이터의 47%를 보여줬다. NN(WSWD) 모델은 빈도수를 정확하게 예측하도록 보정했지만, 주풍향은 1섹터 편차를 보여줬다. 이는 수치적으로 데이터의 값들을 보정하여 빈도수 예측을 잘했지만, 잘못된 방향으로 보정되어 주풍향이 다른 방향으로 변경되었다.

반면에 NN(UV) 모델은 WRF 모델의 데이터를 보정하여 주풍향이 337.5°로 전체 데이터의 56%를 보여주었다. 이는 앞에서 언급한 대로 경향성을 유지함을 알 수 있었다. 또한, 부족한 빈도수를 NN(UV) 모델을 통해 보정되었음을 알 수 있다. 과도하게 빈도수를 예측한 것은 훈련한 데이터들이 주풍향에 밀집되어 있기 때문에 NN(UV) 모델이 과도하게 보정되었다고 생각된다. 이는 앞에서 언급한 바와 같이 신경망 모델의 최적화를 수행하면 개선될 것으로 판단된다.

Figure 3-27 ~ 3-32에 WRF 모델, NN(WSWD), NN(UV) 모델로부터 도출된 풍속 및 풍향 데이터를 측정된 데이터와 비교하였다. Table 10에서 NN(UV) 모델의 MAE 및 RMSE가 NN(WSWD)보다 높았지만, figure 3-29에서 보이듯이 NN(UV) 모델이 다른 모델보다 큰 오차들을 많이 감소한 현상을 육안으로 발견할 수 있다. 특히 측정데이터

는 0~5 m/s이지만, WRF 모델이 과도하게 15~20 m/s로 추정된 데이터가 보정되었다. 이는 Table 3-8에서 IOA와 상관계수(R)이 높은 이유와 동일하다고 볼 수 있다. 이를 통해 UV법은 측정 데이터와 예보 데이터간의 관계성을 해석하는데 도움을 주는 방법론이라고 판단된다.




Fig. 3-23 Measured and predicted wind direction from WRF model.




Fig. 3-24 Measured and predicted wind direction from NN(WSWD) model.




Fig. 3-25 Measured and predicted wind direction from NN(UV) model.

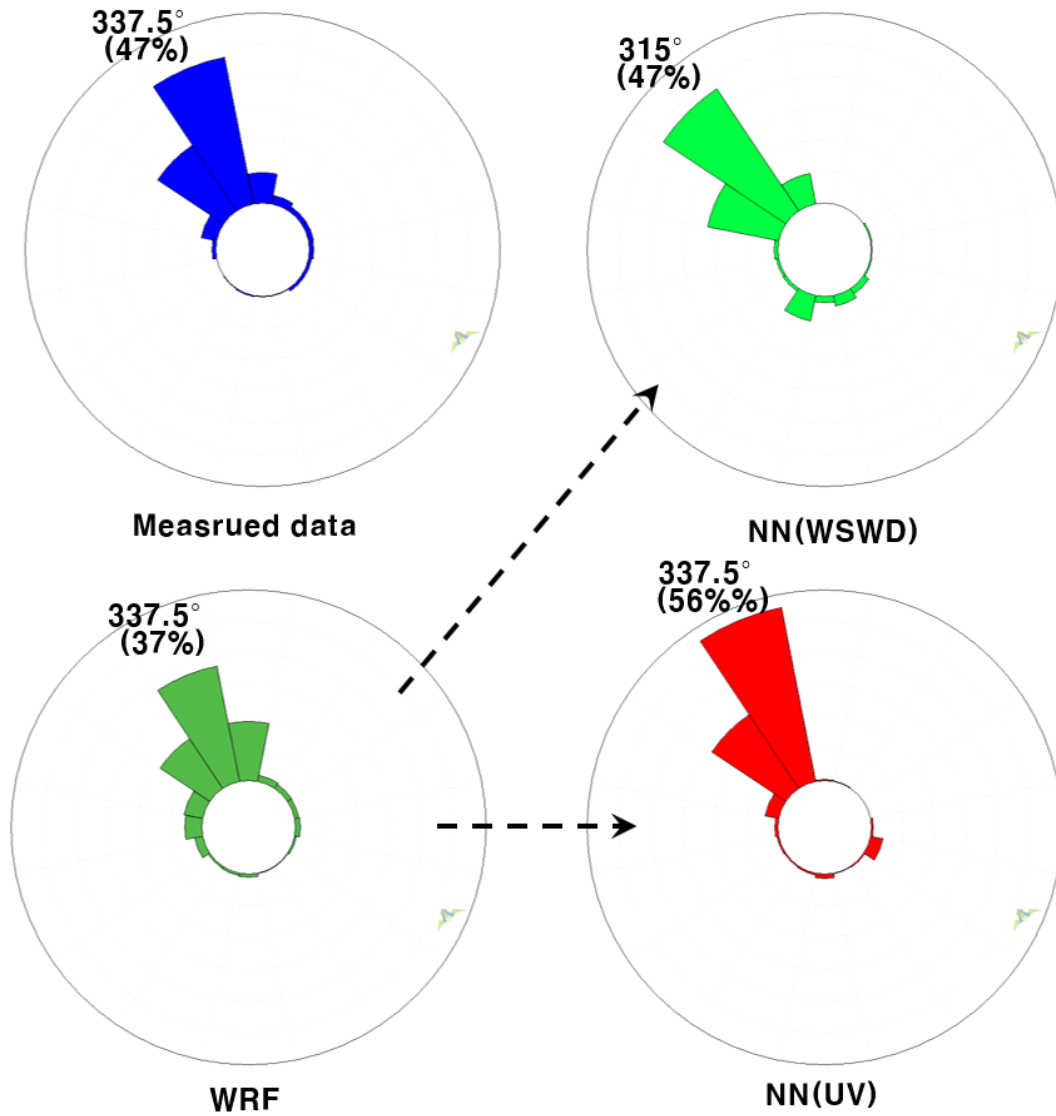


Fig. 3-26 Wind rose from measure data, WRF data, NN(WSWD) data, and NN(UV).




Fig. 3-27 Comparison of wind speed from measured data and WRF data.




Fig. 3-28 Comparison of wind speed from measured data and NN(WSWD) data.




Fig. 3-29 Comparison of wind speed from measured data and NN(UV) data.

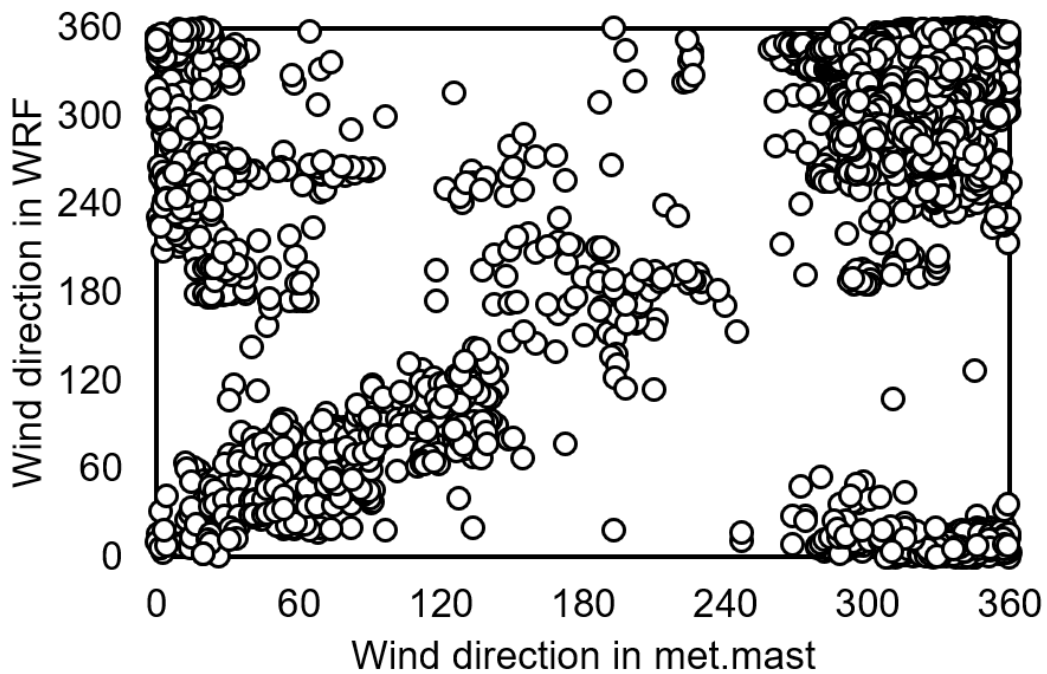


Fig. 3-30 Comparison of wind direction from measured data and WRF data.




Fig. 3-31 Comparison of wind direction from measured data and NN(WSWD) data.




Fig. 3-32 Comparison of wind speed from measured data and NN(UV) data.




Fig. 3-33 MAE results of predicted power production in long-term wind power forecasting. Case 1 is the data set before applying the UV method. Case 2 is the data set after applying only one regression model with the UV method . Case 3 is the dat set after applying a regression model at each forecasting time with the UV method.

장기예보를 대상으로 본 절에서 설명한 회귀모델을 적용하여 단일 회귀모델로 전체 예보기간을 적용한 경우와 일별로 독립적인 다수의 회귀모델을 적용한 경우를 서로 비교해 보았다. 이를 figure 3-33에 도시화 하였다. Case 1은 회귀모델을 적용하지 않은 WRF 모델의 예보 성능을 나타내고 있고, Case 2는 UV법을 통해 단일 회귀모델을 예보 기간 전체에 대해서 적용하였다. Case 3은 Case 2와 동일하게 UV법을 사용했지만, 예보 일별로 독립적인 회귀모델을 생성하여 예보 데이터를 보정하였다.

사용된 데이터는 2018년 1월에 행원기상탑의 50 m 높이에서 측정된 풍속 데이터를 사용하여 회귀모델을 생성하였고, 생성된 회귀모델을 통해 도출된 풍속 데이터를 출력곡선에 대입하여 출력량을 도출했다. 검증용으로 사용된 데이터는 2018년 5월에 행원풍력3호기에서 측정된 출력량 데이터이다.

Case 1의 결과는 6일까지는 낮은 오차를 보여주다가 7일부터 급격하게 오차가 높아지는 현상을 볼 수 있다. 단일 회귀모델을 적용한 Case 2는 풍력터빈의 1일부터 6

일까지 Case 1보다 높은 오차를 보여줬지만, 7일부터 급격하게 높아진 오차를 줄여줬다. 즉, 단일 회귀모델로 인해 특정 값에 보정이 되기 때문에 Case 1의 오차를 평균화했다고 생각된다. 하지만, Case 3은 6일까지 Case 1과 비슷한 수준의 오차를 보여줬으며, 특히 7일 이후에 급격하게 발생된 오차를 Case 2보다 낮은 오차를 도출하였다. 이는 독립적인 다수의 회귀모델이 각 일별로 발생된 편차들을 개별적으로 보정했기 때문이다. 따라서 통계모델을 사용할 경우 예보 정확도가 시간 흐름에 따라 오차가 증가하는 점을 고려하여 시간에 따라 독립적인 모델을 구축하는 것이 합리적이고 생각된다.

3.4. 예보 평가 지표

본 절은 예보 평가에 사용된 지표를 정리하였다. 선택된 평가 지표는 PBias(Persent Bias), MAE(Mean Absolute Error), RMSE(Root Mean Square Error), NRMSE(Normalized RMSE), IOA(Index of Agreement)를 선택했다.

PBias는 식(3-22)과 같고 백분을 단위이고, 0 %에 가까울수록 정확도가 높은 모델을 의미한다. 하지만, PBias는 예보 값의 평균과 측정 값의 평균의 차이를 백분율로 표현한 지표로써 많은 통계량의 정보들이 사라진 지표이다. 이로 인해 단독으로 사용되기엔 통계량 정보가 없다. 단지 부호가 존재하여 과소예측, 과대예측의 의미를 부여할 수 있다. 본 연구에서는 이 지표를 과소예측, 과대예측을 판단하는 기준으로 정했다.

$$PBias = \frac{\sum_{i=1}^N (S_i - O_i)}{\sum_{i=1}^N O_i} \times 100 \quad (3-22)$$

MAE는 식(3-23)과 같고 측정 값과 예보 값의 차이에 절대값을 취하여 평균한 통계

량이다. 절대값을 취하기 때문에 부호는 존재하지 않고 오차의 평균을 나타낸다. 단위는 사용되는 단위를 그대로 채용하고 있다. 즉, 풍속 데이터의 MAE는 m/s로 나타난다. 절대값으로 인해 PBias와 달리 과소예측 및 과대예측된 데이터들이 서로 완충 역할을 하지 못하고 오차값들이 누적되어 산출된다. MAE는 0에 가까운 값일수록 정확도 높은 모델임을 의미한다.

$$MAE = \frac{1}{N} \sum_{i=1}^N |S_i - O_i| \quad (3-23)$$

RMSE는 식 (3-24)과 같고 측정값과 예보 값의 차이에 제곱을 취하여 합산한 후 제곱근을 취하는 식이다. MAE와 마찬가지로 음수는 존재하지 않고 오차의 제곱 평균을 나타낸다. 단위는 MAE와 같고, 오차를 오차 제곱의 평균이므로 MAE보다 높은 값을 도출한다. MAE는 평균값과 비슷한 평균적인 오차를 의미한다면, RMSE는 표준편차와 비슷한 오차들의 표준편차를 의미한다고 볼 수 있다. 이로 인해 MAE와 RMSE의 값이 같을 경우 예보 값과 측정 값의 차이가 동일하게 나타남을 의미한다. 따라서, RMSE이 MAE에 가까울수록 이상치에 해당되는 자료들이 적음을 나타낸다. 반대로 RMSE가 MAE보다 값이 클수록 이상치들이 존재함을 암시적으로 알 수 있다. RMSE/MAE를 비율로 표시하여 특정 기간에서 큰 오차를 나타내고 있는지 또는 균일한 오차를 보여주고 있는지를 판단할 수 있다. RMSE는 MAE보다 작을수 없고, MAE는 RMSE보다 클수가 없다. 따라서 RMSE는 오차를 평가하는 지표들 중에서 가장 높은 값을 도출한다. RMSE는 0에 가까울수록 높은 정확도를 의미한다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i - O_i)^2} \quad (3-24)$$

NRMSE는 식(3-25)와 같고 RMSE를 백분율로 표현한 지표이다. 백분율로 표현하기 위해 사용되는 값은 측정값의 최대 및 최소값의 차이, 측정 데이터의 평균값, 측정 데이터의 표준편차 3종류이다. 평균값과 표준편차는 풍속의 특성상 매년 달라지기 때

문에 일관성 있는 값을 도출하지 못한다. 풍속의 최대 및 최소값은 평균값과 표준편차에 비하면 매년 달라지는 폭이 적다. 이로 인해 본 연구에서는 NRMSE를 측정값의 최대 및 최소값의 차이를 도입하였다. 반면에 측정 데이터가 출력 데이터일 경우 출력 데이터의 최대값인 풍력발전단지의 설비용량을 선택하는게 합리적이라고 생각된다. 풍력발전단지의 설비용량은 새로운 풍력터빈의 설치 또는 철거가 발생하지 않는 이상 풍력발전단지의 설비용량은 변경되지 않는다. 따라서 풍속과 달리 매년 달라지는 기준 값이 존재함으로 출력데이터를 NRMSE로 산출할 경우 식(3-26)와 같이 분모는 설비용량을 사용하는 것이 합리적이다. NRSME는 0에 가까울수록 높은 정확도를 의미한다.

$$NRMSE = \frac{RMSE}{(O_{\max} - O_{\min})} \text{ or } \frac{RMSE}{\bar{O}} \text{ or } \frac{RMSE}{Std.} \quad (3-25)$$

$$NRMSE = \frac{RMSE}{O_{\max}}, \text{ if } O = \text{power data} \quad (3-26)$$

IOA는 식(3-27)와 같고 측정 데이터의 평균값으로부터 측정값과 예보값의 차이를 합산한 다음 제공한 값의 총합을 분모로 두었고, 각 측정값과 예보값의 차이를 제공하여 총합을 분자로 두었다. IOA는 1에 가까운 값이 도출될수록 높은 정확도를 의미한다. 1에 가까운 결과가 나오기 위해서는 예보값이 측정값에 근접해야 한다. 이 상황이 figure 3-34에서 (a) 경우이다. 예보 값과 측정값이 측정 데이터의 평균값을 기준으로 같은 방향으로 위치해야 하고, 예보 값이 측정값에 근접해야 한다. Figure 3-34에서의 (b)와 같이 측정 데이터의 평균값을 기준으로 서로 다른 방향으로 데이터가 위치하면 불일치하다고 판단하여 0인 결과를 도출하게 된다. 즉, IOA는 수치적으로 차이를 나타내는 통계량이 아니고, 예보된 값이 측정값으로부터 얼마나 근접하는지를 1를 기준으로 나타낸 지표이다.





Fig. 3-34 The example of IOA in best case(a) and worst case(b).

$$d = 1 - \frac{\sum_{i=1}^N |O_i - S_i|^2}{\sum_{i=1}^N (|S_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (3-27)$$

본 연구에서 피어슨 상관계수를 사용하지 않았다. 피어슨 상관계수는 두 개의 독립 변수 관계성이 나타남으로 다른 분야에서 많이 사용되고 있다. 하지만, 피어슨 상관계수는 두 개의 독립변수의 관계를 선형성을 가지고 있다는 가정하여 도입된 지표이다. 따라서 독립변수의 관계가 선형적이지 않으면 피어슨 상관계수는 모델의 정확도가 높음에도 불구하고 낮은 수치를 도출한다.

WRF 모델에서 해석된 풍속은 측정된 풍속과 일치 되는 것이 가장 이상적인 예보 결과이다. 하지만, WRF 모델에서 구현되는 scheme들의 해를 구하는 방법은 아직도 수치적인 방법으로 해를 구하여 아직 완벽하게 않다. 또한, 현재 사용되는 scheme들은 자연상태를 완벽하게 구현되었다고 할 수 없다. 따라서 WRF 모델에서 해석되는 풍속은 그 수치에 따라 오차 범위가 달라질 수 있다. 즉, WRF 모델에서 구현되지 않는 기상상태에 의한 오차들은 비선형일 경우가 자연계에서 흔히 존재하는 비선형 관계로 인해 측정값과 관계가 무조건 선형일수는 없다.

피어슨 상관계수는 식(3-28)과 같다. 분모는 x의 평균값에서 각 데이터의 차이를 구한 후 제곱의 총합을 하여 제곱근으로 취하였다. y의 변수도 이와 같게 구하여 서로의 값을 곱한다. 분모는 제곱에 의해 음수가 존재하지 않는다. 반면에 분모의 식에서 제곱과 제곱근을 제외한 식으로 정의된 분자는 양수와 음수가 존재한다. 따라서 피어슨 상관계수의 범위는 -1부터 1까지이고, -1에 가까울수록 x, y의 관계는 음의 관계를 가졌다고 하고, +1에 가까울수록 양의 관계를 가졌다고 한다. 또한, 0에 가까울수록 x와 y는 서로 관계성이 없다고 한다.

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}} \quad (3-28)$$




Fig. 3-35 Description of quadrants based on the mean of x, y values in Pearson correlation coefficient.

Figure 3-35에서 보이듯이 데이터가 각 평균값을 기준으로 1-4사분면 중에서 위치한 곳에 따라 양수 또는 음수로 분류되고, 1사분면과 3사분면에 데이터가 집중되어 있으면 양수로 산출되고, 2사분면과 4사분면에 데이터가 집중되어 있으면 음수로 산출된다.

피어슨 상관계수의 값은 데이터의 평균값을 기준으로 거리를 산출하여 $(x_i - \bar{x}, y_i - \bar{y})$ 제공하여 제곱근을 취한 값과 그대로 합산한 값의 비율로 나타낸 값이다. 즉, 각 데이터들의 거리를 양수로 취하여 총합을 구한 값을 기준으로 양수, 음수가 존재하는 데이터 거리의 합을 구하여 비율로 표현한다. 의미적으로만 보면 1,3사분면에 있는 데이터의 수와 2,4사분면에 있는 데이터의 수를 비교하여 비율로 표현한 것과 비슷하다고 볼 수 있다.

이와 같이 피어슨 상관계수는 데이터들의 관계성을 중심으로 산출함으로 IOA와 달

리 데이터의 근접함을 나타낼 수는 없다. 물론 아직까지도 피어슨 상관계수가 1에 가까운 값을 나타내면 모델의 성능도 우수하다고 나타낸다. 하지만, 서로 다른 모델의 성능을 표현하기엔 부족하다고 생각된다.

4. 실시간 풍력발전량 예보 정확도 평가

개념설계와 상세설계를 통해 실시간 풍력발전량 예보 시스템을 구축하였다. 구축된 예보는 장기예보와 중기예보이고, 중기예보는 72시간을 예보하여 1시간 간격으로 풍속을 예보하였다. 장기예보는 14일을 예보하여 1일 간격으로 발전량을 예보하였다. 예보대상은 단일 풍력터빈으로 행원풍력3호기 Vestas V47-660kW이다. 허브높이는 45 m이므로 40 m의 예보자료와 50 m의 예보자료를 사용하여 45 m에서의 풍속을 예보하였다. 중기예보의 수평해상도는 0.9 km이고, 장기예보의 수평해상도는 8.1 km이다.


본 장은 예보 정확도를 평가하기 위한 연구 대상을 설명하고, WRF 모델에서 예보된 풍속 정확도를 평가한 다음 발전량 예보에 대한 정확도를 평가하였다. 또한, 풍력터빈에 영향을 주는 공기밀도 정확도를 분석하기 위해 온도 및 압력에 대한 정확도를 살펴보았다.

4.1. 연구 대상

제주도 행원풍력발전단지에 설치된 행원3호기는 제주대학교 풍력사업단에서 운영하고 있는 풍력터빈이다(table 4-1). 이를 대상으로 풍력발전량 예보 시스템을 개념설계부터 상세설계까지 수행하였다. 행원3호기는 Vestas사에서 제작한 V47-660kW 모델이고, 허브높이 45 m, 정격출력은 660 kW이다. 풍력사업단에서 자체적으로 운영중인 SCADA system을 이용하여 행원3호기의 출력량을 취득했다.

풍속 예보에 대한 검증은 제주에너지공사에서 운영 중인 행원 기상탑에서 관측한 자료를 사용하였다. 행원 기상탑은 풍속계가 지면높이 80 m, 75 m, 70 m, 50 m, 35 m에 설치되었으며, 풍향계는 지면높이 75 m, 67 m, 50 m에 설치되었다(figure 4-1).

Table 4-1 Summary of Hang-won wind turbine #3.

	Turbine Model	Vestas V47-660kW
	Class	IEC Ia
	Power	660 kW
	Hub Height	45 m
	Rotor Diameter	47 m
	Cut-in speed	4.5 m/s
	Cut-out speed	25 m/s
	Control	FSVP
	Rotor RPM	28.11 ~ 31.23
	Gen. RPM	1818 ~ 1980
	Voltage	690V/60Hz

센서가 설치된 방향은 45° 와 225° 로 설치되었다. 70 m에서는 풍속계가 2개 설치되었으며 67 m에 풍향계가 2개 설치되었다. 온습도 및 압력계는 지면높이 65 m에 설치되었다. 온도 및 압력 데이터는 공기밀도를 산출하는데 사용하였다.

행원 기상탑과 행원3호기의 SCADA 데이터의 수집기간은 2018. 1. 1 ~ 1. 31과 2018. 4. 18 ~ 5. 28이다. 첫 번째 데이터 그룹은 기상수치모델의 검증에 사용했고, 두 번째 데이터 그룹은 첫 번째 데이터 그룹을 이용하여 후처리 보정법을 도입한 후 최종적으로 도출된 예측정확도를 검증하는데 사용하였다.

본 절은 행원풍력 3호기를 대상 풍력발전량 예보 시스템의 개념설계를 진행하고자 한다. 예보 목적은 풍력터빈의 원활한 운영을 목적으로 결정했다. 예보시간은 중기예보(3일)와 장기예보(2주)를 선택하여 장기예보를 통해 장기적으로 운영계획을 설계하고 중기예보로 다가오는 계획을 재점검 및 수립할 수 있도록 구성을 했다. 중기예보의 예보 해상도는 풍력터빈의 유지보수 수행 시 작업자의 안전한 풍속을 확인하기 위해서 시간 단위를 선택했다. 시간대별 평균풍속을 통해 작업시작 시간, 종료 시간,

Type of sensors is Theis 1st class advanced

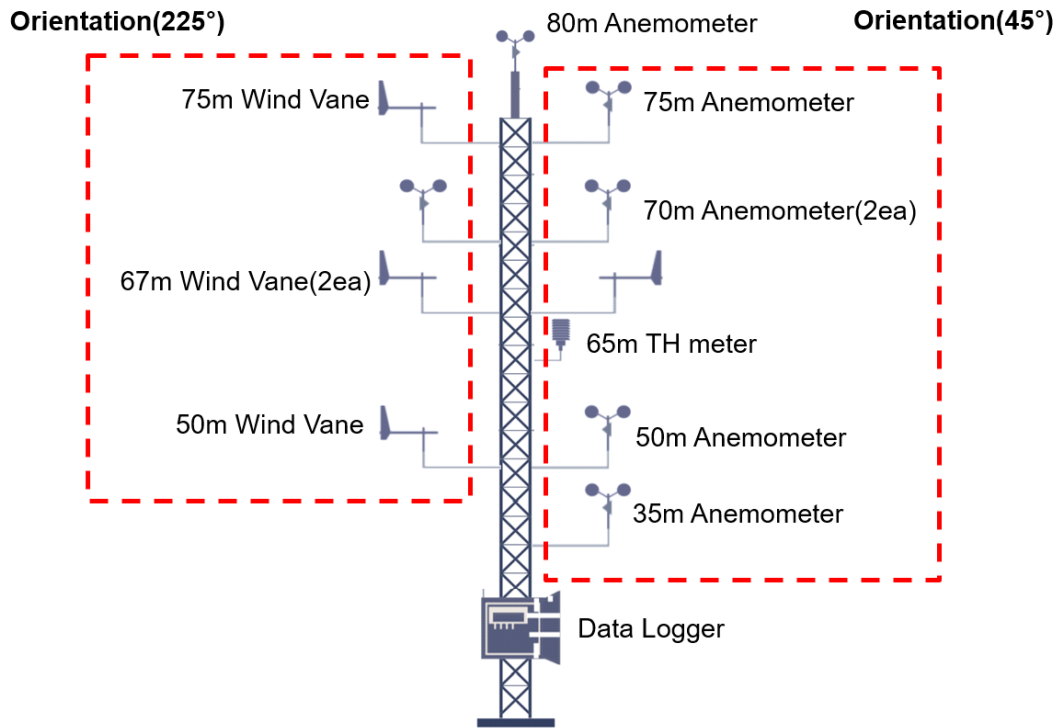


Fig. 4-1 Summary of Hang-won met.mast.

총 작업시간을 파악할 수 있기 때문이다. 이로 인해 자료는 1시간 평균풍속으로 도출하였다. 장기예보는 일 단위로 결정하여 1일 누적 발전량이 도출 되도록 했다. 이는 장기적인 계획을 수립할 때 유지보수 또는 긴급보수를 수행하여 발생하는 손실액을 산출할 수 있기 때문이다. 즉, 장기예보는 계획 수립 시 최소의 손실액을 파악하는데 집중하고, 중기예보는 작업자의 안전을 우선순위로 두고, 계획을 재점검 및 수립 할 수 있다.

예보 방법은 기상수치모델을 선택했다. 기상수치모델은 중규모 모델인 WRF를 채용했고, 행원풍력 3호기를 중심으로 기상을 예보하였다. WRF의 scheme는 연구사례들을 참고하여 선택하였다. Microphysics는 WSM 6-class graupel scheme이고, Radiation(Longwave & Shortwave)는 RRTMG scheme를 선택했다. PBL은 YSU scheme를 선택했으며, Cumulus parameterization은 첫 번째 도메인인 경우 Kain-Fritsch scheme를 선택했고, 두 번째 도메인부터는 Grell-Devenyi ensemble scheme를 선택했

다. LSM은 3장에서 예보 정확도가 높은 Noah-MP LSM을 선택하였다.

Terrestrial data는 WRF에서 제공하는 기본 자료를 사용하였고, 오직 1 km 격자 도메인에서만 지형자료를 상세 지형자료로 사용하였다. 상세 지형자료는 국토지리정보원에서 제공하는 1:5000 비율로 제작된 디지털 지형자료를 이용하여 입력하였다. 기상자료는 1° 간격으로 생성된 GFS 파일을 선택하였다.

WRF 모델의 수평해상도는 첫 번째 도메인의 수평해상도 24.3 km부터 시작하여 두 번째 도메인은 8.1 km, 세 번째 도메인은 2.7 km, 네 번째 도메인은 0.9 km로 구성하였다. 0.9 km 까지 구성한 이유는 예보 대상이 단일 풍력터빈이고, 추후 LES를 적용한 수평해상도 100 m까지를 고려하기 위한 설정법이다. 또한, WRF 모델은 하위 도메인을 구성하여 도메인의 수평해상도를 조밀하게 구성하는 downscaling 기법(Lo et al., 2008)을 채용하고 있다. 이 downscaling 기법은 WRF 모델에서는 상위 도메인과 하위 도메인의 수평해상도 비율을 1:3으로 권장하고 있다. 이를 적용하면 0.9 km부터 3배씩 증가하여 24.3 km가 도출하게 된다. 24.3 km 까지 확장한 이유는 선택된 GFS 파일이 1° 간격으로 약 50 km으로 볼 수 있는데, GFS의 격자 1칸이 첫 번째 도메인의 4개로 분할되도록 구성하여 GFS의 기상정보가 서서히 분할되도록 구성함에 있다. 또한, 1개의 격자내부에서 급격하게 많은 격자로 분할하는 방식은 WRF 모델에서도 비추천하고 있다.

WRF 모델의 수직해상도는 상층기류와 하층기류가 서로 기상상태를 잘 교환하기 위해 구성해야 한다. WRF user 가이드에서는 수직해상도를 1 km 이내로 구성하기를 추천하고 있다. 이를 반영하기 위해 수직해상도를 1 km로 구성하여 전체적인 기상상태를 해석하기 위한 기본 층을 구성하였다. 게다가 풍력터빈의 허브높이에 해당하는 풍속을 예보하기 위해서 풍력터빈의 허브높이를 수직층에 추가하였다. 이를 풍력용 수직층이라고 정의했고, 0 m ~ 150 m까지 10 m 간격으로 구성하였다. 이 범위는 현재 상업용으로 운전하는 3 MW급 풍력터빈의 전체 높이를 포함하는 높이이다.

도메인의 그리드는 첫 번째 도메인인 경우 한반도 전체가 포함되도록 70 × 70으로 구성하였다. 이는 한반도에서 발생하는 고기압 및 저기압을 하위 도메인에 전달하기 위함이다. 70 × 70은 한 격자가 24.3 km이므로 전체 도메인 크기는 1,701 km이다. 본 연구에서 설정된 도메인은 table 7에 정리하였다.

4.2. 풍속 예보 정확도 결과

행원풍력 3호기에서 취득한 풍속 데이터와 WRF 모델에서 예보된 풍속 데이터를 비교분석하였다. 중기예보는 시간 해상도가 시간단위이기 때문에 정확도 결과는 1시간 평균 풍속을 기준으로 산출되었다. 장기예보는 시간 해상도가 일단위이기 때문에 정확도 결과는 1일 평균 풍속을 기준으로 산출되었다. 이와 마찬가지로 기상탑 데이터도 중기예보인 경우 1시간 평균풍속으로 산출하여 비교하였고, 장기예보인 경우 1일 평균풍속을 산출하여 비교하였다.

중기예보에서는 PBias가 -8.62%로 과소예측 되었고, MAE가 1.99 m/s, RMSE가 2.53 m/s로 보여졌다. NRMSE는 11.4%의 오차를 보여줬고, IOA는 0.91로 높은 일치성을 보여줬다(table 4-2). 장기예보에서는 PBias가 1.31%로 과대예측 되었고, MAE가 2.54 m/s, RMSE가 3.39 m/s로 보여졌다. NRMSE는 20.8%의 오차를 보여줬고, IOA는 0.79로 다소 높은 일치성을 보여줬다.(table 4-3).

중기예보의 데이터를 도시화한 Figure 4-2를 살펴보면, 피어슨 상관계수는 0.86으로 양의 관계성을 나타냈다. 일부 데이터가 측정 풍속 데이터보다 높게 예보되었지만, 대부분의 예보된 데이터가 측정 데이터와 유사함을 알 수 있었다.

장기예보의 기간을 1~7일인 1주차와 8~14일인 2주차로 분할하여 기상탑 데이터와 비교하였다(table 4-3). 1주차 결과는 PBias가 -2.19%로 과소예측 되었고, MAE가 1.66 m/s, RMSE가 2.10 m/s로 보여졌다. NRMSE는 12.9 %의 오차를 보여줬고, IOA는 0.93로 높은 일치성을 보여줬다. 반면에 2주차 결과는 PBias가 4.86%로 과대예측 되었고, MAE가 3.42 m/s, RMSE가 4.32 m/s로 1주차 결과보다 오차가 급격하게 증가하였다. 또한 NRMSE는 28.8%의 오차를 보여주어 약 16% 증가한 결과를 보여줬다. IOA는 0.62로 약 0.3만큼 낮아졌다.

Figure 4-3은 중기예보의 시간대별 MAE와 RMSE의 결과를 보여준다. MAE가 최소 1.43 m/s에서 최대 2.61 m/s까지 미미하게 증가하는 추세가 나타났고 RMSE가 최소 1.73 m/s에서 최대 3.60 m/s까지 증가하는 추세를 볼 수 있었다. 이로 인해 예보기간

인 3일 동안 오차가 증가하는 사실을 알 수 있다.

Figure 4-4은 장기예보의 일별 MAE와 RMSE의 결과를 보여준다. MAE가 최소 0.98 m/s에서 최대 4.10 m/s까지 약 3 m/s 증가하는 추세를 보여줬고, RMSE가 최소 1.33 m/s에서 최대 5.13 m/s까지 약 4 m/s 증가하는 추세를 보여줬다. 이는 중기예보에서 예보시간의 흐름에 따라 오차가 증가하는 사실과 같은 사실을 알려준다. 또한, 예보 시간이 긴 장기예보인 경우 증가하는 수준이 높다는 것을 알 수 있었다. 특히 1주차 이후부터 오차가 급격하게 증가하는데 이는 초반에 내포된 기상상태의 오차가 점차 증가하여 1주일 뒤에는 실제 기상상태와는 상이한 기상상태로 예보된 것으로 생각된다.

Table 4-2 Statistical measures for wind speed in the medium-term wind power forecasting.

PBias[%]	MAE[m/s]	RMSE[m/s]	NRMSE[%]	IOA
-8.62	1.99	2.53	11.4	0.91

Table 4-3 Error of wind speed are classified into three periods in long-term.

Period	1~14days	1~7days	8~14days
PBias[%]	1.31	-2.19	4.86
MAE[m/s]	2.54	1.66	3.42
RMSE[m/s]	3.39	2.10	4.32
NRMSE[%]	20.8	12.9	28.8
IOA	0.79	0.93	0.62




Fig. 4-2 Comparison of wind speed from measured data and WRF data in medium-term(72h). $R=0.86$, $IOA=0.91$.




Fig. 4-3 Forecasting error of MAE, RMSE for hourly wind speed in medium-term.




Fig. 4-4 Forecasting error of MAE, RMSE for hourly wind speed in long-term.

4.3. 풍력발전량 예보 정확도 결과

행원풍력 3호기에서 취득한 발전량 데이터와 WRF 모델에서 예보된 풍속 데이터를 출력곡선에 대입하여 예측된 발전량 데이터를 비교분석하였다. 중기예보에서는 PBias가 16.20%로 과대예측 되었고, MAE가 180.32 kWh로 27.3%의 오차를 보여줬다. RMSE는 245.61 kWh로 37.2%의 오차를 보여줬고, NRMSE는 37.21%의 오차를 보여줬다. IOA는 0.71로 나타났다(table 4-4).

장기예보에서 시간대별 생산량에 대한 정확도를 평가하였다. PBias가 -27.85%로 과소 예측되었고, MAE가 252.39 kWh, RMSE가 319.64 kWh로 보여줬다. NRMSE는 48.5%의 오차를 보여줬고, IOA는 0.48로 낮은 일치도를 보여줬다(table 4-5). 1주차 정확도 결과는 PBias가 -5.97%로 과소예측 되었고, MAE가 224.14 kWh, RMSE가 281.14 kWh이고 NRMSE는 42.7%의 오차를 보여줬다. IOA는 0.54로 소폭 상승한 일치도를 보여줬다. 2주차 정확도 결과는 PBias가 -4.86%로 과소예측 되었고, MAE가 280.20 kWh,

RMSE가 353.46 kWh로 나타났다. NRMSE는 53.6%로 오차가 증가했으며 IOA는 0.45로 낮은 일치도를 보여줬다.

장기예보에서 일일생산량에 대한 정확도를 평가하였다(table 4-6). 전체기간에서 대해서는 PBias가 -2.78%로 동일하게 과소평가 되었고, MAE가 4.28 MWh, RMSE가 5.64 MWh로 나타났으며 NRMSE는 36.3%의 오차를 보여주면서 IOA가 0.51로 평가되었다. 1주차 결과는 PBias가 16.68%로 과대평가되었고, MAE가 3.68 MWh, RMSE가 4.80 MWh로 나타났다. NRMSE는 30.8%의 오차를 보여주었고, IOA는 0.63으로 평가되었다. 2주차 결과는 PBias가 -21.20%로 과소평가되었고, MAE가 4.85 MWh, RMSE가 6.34 MWh로 나타났다. NRMSE는 40.8%의 오차를 보여주었고, IOA는 0.41로 평가되었다.

장기예보는 동일한 시간대별 생산량을 비교한 결과 중기예보보다 높은 오차를 보유했다. 또한, 1주차 결과가 2주차 결과보다 정확도는 높았으나, 큰 차이는 나타나지 않았다. 반면에 장기예보의 일일생산량에 대한 정확도 결과는 1주차의 결과가 과대평가되었지만, 2주차의 결과에서 과소평가되었다. 또한, NRMSE의 결과가 10%의 차이를 보여주어 1주차와 2주차의 오차 특성이 다를 수 있었다. 이는 장기예보의 풍속 정확도와 비슷한 결과임을 알 수 있었다.

중기예보의 시간대별 MAE는 최저 95 kWh에서 최대 266 kWh로 나타났고, RMSE는 최저 140 kWh에서 최대 355 kWh로 나타났다(figure 4-5). MAE가 낮아지면 RMSE도 같이 낮아졌고, MAE가 높아지면 RMSE도 같이 높아졌다. RMSE와 MAE의 비율이 1.2~1.3에 분포하고 있다. 이는 WRF 모델에서 내포하고 있는 평균적인 오차를 내포하면서 부분적으로 기상현상에 급격한 오차를 내포함을 의미한다.

기상현상에서 평균적으로 발생하는 오차는 잘못된 초기조건에 의해 발생하는 오차로 볼 수 있다. 이는 WRF 모델의 downscaling 기법 또는 지형자료 및 토지피복도의 상세한 자료를 통해 향상될 수 있다. 또한 WRF 모델의 후처리 보정을 통해 평균적으로 발생하는 오차를 줄일 수 있다.

하지만, 기상현상에서 급격하게 발생하는 오차는 기상이 급격하게 변화하는 현상 또는 잘못된 경계조건에 의해 발생하는 오차로 볼 수 있다. 이는 기상모델의 한계점으로 볼 수 있으며, 기상모델의 scheme 향상 및 실제 기상현상을 고려하지 못하는 요소들을 연구하여 지속적으로 정확성을 향상시켜야 개선이 될 수 있다. 또 다른 대안으로 WRF 모델과 통계모델을 결합한 hybrid 모델을 통해 WRF 모델에서 해결할

수 있는 문제점 및 오차들을 통계모델을 통해 급격한 오차들을 보정할 수 있다. 발전량 중기예보는 풍속 중기예보와 달리 예보시간의 흐름에 따라 증가하는 추세는 존재하지 않았다.

Table 4-4 Statistical measures for hourly wind power production in the medium-term wind power forecasting.

PBias[%]	MAE[kWh]	RMSE[kWh]	NRMSE[%]	IOA
16.20	180.32	245.61	37.21	0.71

Table 4-5 Statistical measures for hourly wind power production in the long-term wind power forecasting.

Period	1~14days	1~7days	8~14days
PBias[%]	-27.85	-5.97	-4.86
MAE[kWh]	252.39	224.14	280.20
RMSE[kWh]	319.64	281.14	353.46
NRMSE[%]	48.5	42.7	53.6
IOA	0.48	0.54	0.45

Table 4-6 Statistical measures for daily wind power production in the long-term wind power forecasting.

Period	1~14days	1~7days	8~14days
PBias[%]	-2.78	16.68	-21.20
MAE[MWh]	4.28	3.68	4.85
RMSE[MWh]	5.64	4.80	6.34
NRMSE[%]	36.3	30.8	40.8
IOA	0.51	0.63	0.41




Fig. 4-5 Forecasting error of MAE, RMSE for hourly power production in medium-term. MAE : 95~266 kWh, RMSE : 140~335 kWh.

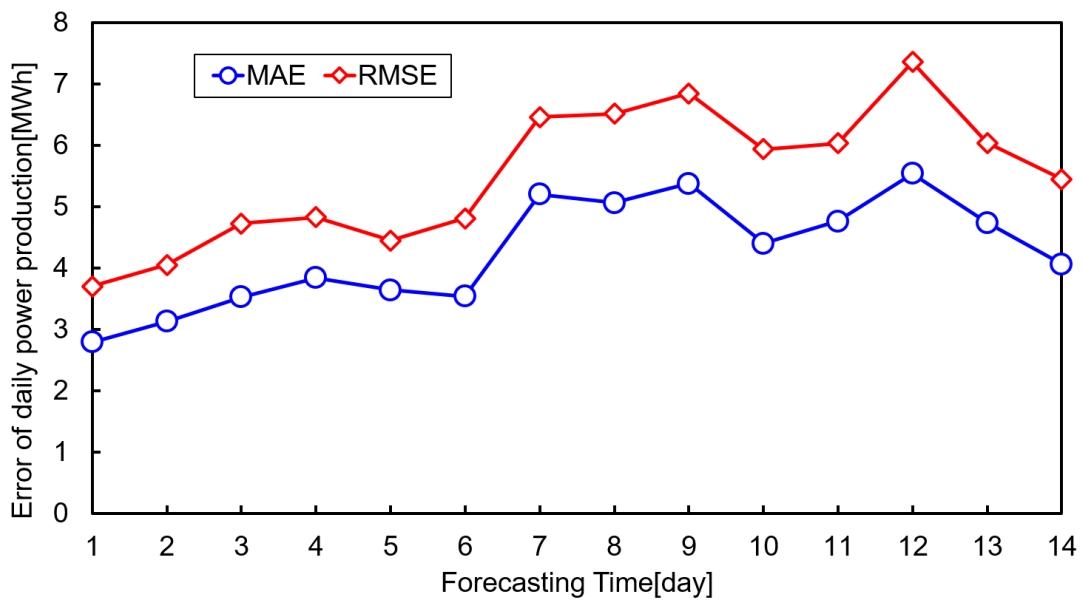


Fig. 4-6 Forecasting error of MAE, RMSE for daily power production in long-term. MAE : 2.79~5.54 MWh, RMSE : 3.70~7.36 MWh.

장기예보는 일일생산량에 대한 MAE는 최소 95에서 최대 266 MWh로 나타났고, RMSE는 최저 3.79 MWh에서 최대 7.36 MWh로 나타났다(figure 4-6). 중기예보와 마찬가지로 MAE와 RMSE의 추세는 서로 같았다. 장기예보는 7일부터 오차가 급격하게 증가하였다. 이는 기상모델이 7일 이후부터 급격하게 실제 기상상태와 다른 기상으로 예보됨을 의미한다. 한반도에서 저기압 및 고기압은 최소 3~5일 정도 머물다가 이동을 한다. 따라서 초기에 존재하는 저기압 및 고기압이 이동한 후 새로운 저기압 또는 고기압이 유입될 경우 상이한 기상상태를 예보함으로써 이 영향들이 풍력발전량 예보에는 오차로 나타남을 알 수 있었다.

풍력터빈은 풍속에 따라 급격하게 출력량이 변동하는 구간을 보유하고 있다. 이 구간은 토크제어를 하는 정격풍속이하 구간이다. 이처럼 출력량의 감소 및 증가가 큰 현상을 ramp라고 정의한다(Hwang et al., 2012). 이 ramp 특성이 풍력터빈에는 빈번히 발생하고 있는데 본 연구에서는 ramp 특성이 전혀 고려되지 않았다. 따라서 ramp 특성이 고려가 되면 오차를 급격하게 줄일 수 있다고 생각된다.

중기예보에서는 전체적으로 낮은 오차를 보여줬지만, 장기예보에서는 특정 예보 시점을 기준으로 예보 정확도가 급격하게 변화하는 현상을 발견하였다. 기상요소인 압력, 온도의 예보 정확도를 살펴본다 풍력에너지밀도와 연관된 공기밀도의 정확도를 추가로 살펴보았다.

Figure 4-7은 압력과 온도의 MAE 결과를 일별로 나타냈다. 7일까지는 압력과 온도가 약 2°C와 2hPa의 오차를 유지하다가 8일을 기점으로 오차의 변동이 커졌다. 이는 8일 이후부터 더 이상 지표면 모델에서 복사열에 대한 정확도가 낮아져 온도의 오차가 커졌다고 볼 수 있다. 또한, 압력의 오차는 고기압 또는 저기압의 상태 및 위치에 대한 오차가 증가하고 있어서 압력의 오차가 급격하게 증가했다고 볼 수 있다.

장기예보의 자료를 1주차(1일~7일) 예보자료와 2주차(8일~14일) 예보자료로 분류하여 온도, 압력, 공기밀도의 자료를 살펴보았다. 1주차 예보자료의 압력 데이터를 측정자료와 비교하면 MAE가 2.38hPa로 낮았고, IOA는 0.92로 높은 일치도를 보였다. 상관계수는 0.92로 양의 관계가 높았다. 반면에 2주차 예보자료와 측정자료를 살펴보면 MAE는 3.80hPa로 1주차 예보자료의 결과보다 높았고, IOA는 0.68로 0.24만큼 낮은 일치도를 보였다. 상관계수는 0.57로 약 0.3만큼 양의 관계가 감소되었다.

1주차 예보자료의 온도 데이터를 측정자료와 비교하면 MAE가 2.01°C로 비교적 낮

았고, IOA는 0.92로 높은 일치도를 보였다. 상관계수는 0.93로 양의 관계가 높았다. 반면에 2주차 예보자료와 측정자료를 살펴보면 MAE는 3.11°C로 약 1°C 정도 높았고, IOA는 0.76으로 0.16만큼 낮은 일치도를 보여줬다. 상관계수는 0.59로 약 0.3만큼 양의 관계가 감소되었다.

예보자료의 온도와 압력을 사용하여 공기밀도를 산출하였다. 산출된 공기밀도를 측정된 온도와 압력으로부터 산출된 공기밀도와 비교하였다. 1주차 예보자료의 공기밀도 데이터를 측정자료와 비교하면 MAE가 0.01 kg/m³로 낮은 오차를 보여줬고, IOA는 0.97로 높은 일치도를 보였다. 상관계수는 0.94로 양의 관계가 높았다. 반면에 2주차 예보자료와 측정자료를 살펴보면 MAE는 0.02 kg/m³로 낮은 오차를 보여줬다. 그러나 IOA는 0.76으로 0.21만큼 낮은 일치도를 보여줬고, 상관계수는 0.61로 약 0.3만큼 양의 관계가 감소되었다.

장기예보 데이터를 1주차 예보자료와 2주차 예보자료로 분류하였다. 1주차 예보자료에서 예보된 압력, 온도, 공기밀도는 측정된 자료와 일관성 있는 결과를 보여주었다. 반면에 2주차 예보자료에서는 예보된 압력, 온도, 공기밀도가 측정된 자료와 불규칙한 결과를 보여주었다. 또한, 육안으로도 데이터가 불규칙한 패턴을 보여주고 있어서 정량적으로 낮은 오차를 보여주었지만, 의미 없는 기상정보가 도출되었다고 볼 수 있다.




Fig. 4-7 MAE of pressure and temperature in long-term wind power forecasting




Fig. 4-8 Pressure data from 1day to 7day(MAE = 2.38hPa, IOA = 0.92, R = 0.92).




Fig. 4-9 Pressure data from 8day to 14day(MAE = 3.80hPa, IOA = 0.68, R = 0.57).




Fig. 4-10 Temperature data from 1day to 7day(MAE = 2.01°C, IOA = 0.92, R = 0.93).




Fig. 4-11 Temperature data from 8day to 14day(MAE = 3.11°C, IOA = 0.76, R = 0.59).

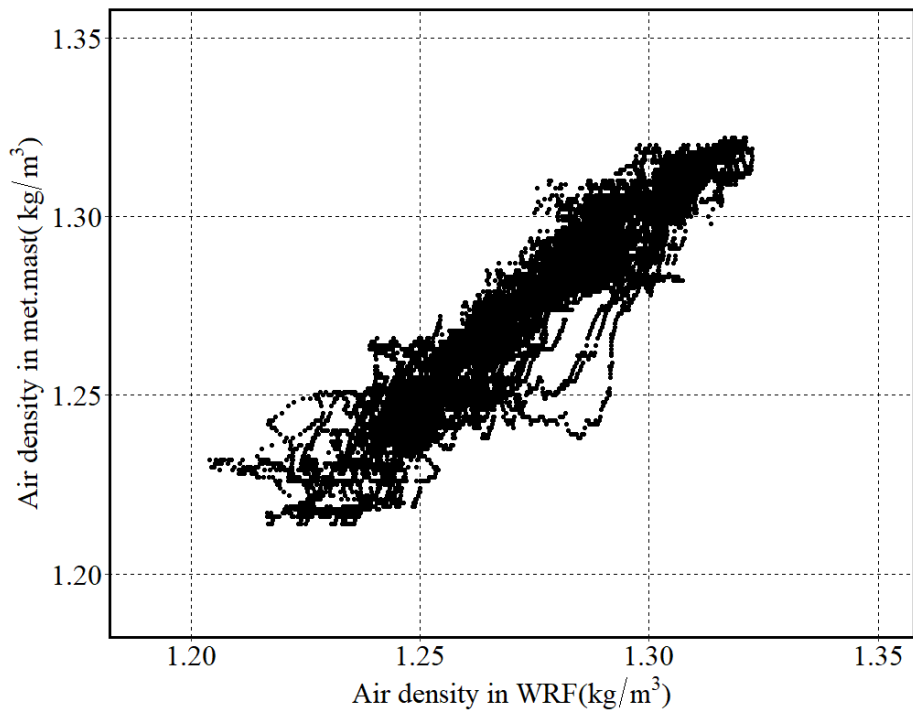


Fig. 4-12 Air density from 1day to 7day(MAE = 0.01kg/m^3 , IOA = 0.97, R = 0.94)




Fig. 4-13 Air density from 8day to 14day(MAE = 0.02kg/m^3 , IOA = 0.76, R = 0.61).

5. 실시간 풍력발전량의 변동성 평가

풍력발전량 변동성 예보(Wind power uncertainty forecasting)는 확률론적 예보(probabilistic forecasting)(Bremnes, 2004), 위험지표(risk index)(Pinson and Kariniotakis, 2004), 시나리오 예보(scenario forecasting)(Pinson et al., 2009), 3가지로 분류된다.

확률론적 예보는 확률밀도함수(probability density function), 누적분포함수(cumulative distribution function), 변위수와 간격(quantile and interval) 등을 이용하여 풍력발전량을 확률변수로서 정의된 확률분포를 따른다고 가정하여 예보를 한다. 확률론적 예보는 사용자에게 풍력발전량의 대푯값과 범위를 제시함으로써 의사결정이 필요한 분야에서 많이 쓰이는 방법이다. 3가지 예보 중 가장 관심 있는 방법론이다.

위험지표 예보는 확률론적 예보와 다르게 하나의 값으로 표현된다. 위험지수가 높으면 발전량 예보가 높은 오차를 보유할 가능성이 크다는 것을 의미한다. 이를 색깔로 표현하거나(e.g. red-green-yellow), 정수형인 숫자로 표현되어(e.g. 1,2,...,7), 재난 경고와 같은 의미로 쓰인다. 예를 들면, 예보대상 구역의 기상상태가 안정된 상태가 불안정한 상태보다 오차가 크다면, 안정적인 기상상태일 경우 위험지수를 높게 평가한다.

시나리오 예보는 다른 예보와 달리 예보시점을 고려하는 예보이다. 풍력터빈과 에너지저장장치(energy storage system)간의 운영에 따른 시나리오, 다단계 의사결정에 의한 시나리오, 유지보수에 의한 시나리오 등 시간에 따라 발생하는 이벤트에 의해 발생하는 변동성을 평가하여 예보를 수행한다. 주로 결합 확률밀도함수(joint probability density function)에 의해 구성이 되는데, 의사결정에서 직접적으로 사용되기엔 애로사항이 존재한다. 따라서 이 대안으로 하나의 값을 제공하는 point forecasting를 다수 생성하여 제공한다. 추가로, 시나리오 예보는 시공간적 상태를 동시에 고려하여 예보하기도 한다. 이는 풍력터빈의 위치, 지형에 따른 시나리오를 만들어 추가로 고려하는 방법이다.

본 연구에서는 확률론적 예보를 적용하기 위해 MCS(Monte Carlo Simulation)을 적용하였다. 변동성 요소로는 WRF 모델의 풍속 변동성과 풍속을 출력으로 변환해 주는 출력곡선에 대한 변동성을 평가하였다.

5.1. MCS 방법론

MCS(Monte carlo simulation)는 어떤 조건이 변화할 때 마다 어떻게 결과가 달라지는지를 검증하는 What-if 분석법 중 하나이다. MCS를 통해 의사결정을 함수화하여 가상으로 조건에 따라 결과를 도출해 봄으로써 실제 상황에서의 결과를 예측하는 모의실험이라고 볼 수 있다. 시뮬레이션에서 사용하기 위한 값을 확률분포로 정의하여 정의된 확률분포에서 임의적으로 선택하는 표본추출(sampling)을 사용하고 있고, 이를 모의적 표본추출법(Simulated sampling technique)이라고도 한다. MCS는 임의의 난수를 통해 입력에 해당하는 변수를 변경하여 모든 경우의 수를 발생한 다음 그 결과에서 발생하는 분포와 통계량을 제공한다.

JCGM(Joint Committee for Guides in Metrology)에서는 측정에 대한 불확도 평가방법을 JCGM 100:2008과 JCGM 101:2008에 명시하였다. JCGM 100:2008는 GUM guideline이라고 불리는 전통적인 방법이고, JCGM 101:2008는 MCS를 이용한 불확도 평가방법을 채용하고 있다. GUM guideline는 불확도 요소들간의 관계가 선형관계라고 가정하여 불확도를 평가하는 LPU(Law of propagation of uncertainty) 방식을 이용하여 불확도의 값들을 이용하여 합성불확도(각 불확도 요소들에서 추정된 불확도 값들을 합성한 불확도를 의미함)를 도출한다.[Carobbi, 2010] JCGM 101:2008에서 채용된 MCS는 LPD(Law of propagation of distirubtion) 방식을 이용하여 불확도 요소들에 대해 정의된 분포도에서 발생가능한 경우의 수를 모두 산출하여 합성불확도를 도출한다.[Farrance and Robert, 2014](figure 5-1)




Fig. 5-1 GUM approach(law of propagation of uncertainty) and MCS approach(law of propagation of distribution) in uncertainty estimation.

GUM approach는 불확도 요소들간의 관계성이 선형으로 가정하기 때문에 비선형관계를 나타내는 문제에서는 부적합하기 때문에 MCS approach를 통해 비선형 문제를 해결하는 것이 합리적이다.[Mahmoud and Hegazy, 2017] 풍력분야에서는 풍속을 출력으로 변화해주는 출력곡선을 예로볼 수 있다. 출력곡선은 풍속의 3제곱에 비례하는 출력을 산출함으로 선형관계를 가정하는 GUM approach에 부적합하다고 판단되어 MCS approach를 채용하여 본 연구에서 적용하였다.

JCGM에서 언급하는 불확도는 측정에 관한 불확도를 의미한다. 일반적으로 사용된 측정기기의 불확도, 주변환경에 따른 불확도, 데이터의 수에 따른 불확도를 불확도 요소로 선정하여 평가하고 있다. 본 연구에서는 측정기기를 사용하는 불확도를 의미하지 않는다. 오직 사용된 모델에 대한 불확도를 평가하였다. 따라서 이를 구분하기 위해 변동성으로 정의하였다.

예를 들면 출력곡선 불확도는 IEC 61400-12-1 국제표준에 의해 불확도가 평가된다. IEC 61400-12-1은 측정기기를 통해 불확도를 평가하고 수집된 데이터의 평균값에 대한 오차를 분석하여 출력곡선의 신뢰성을 보장해 주고 있다. 하지만 보장된 출력곡선을 이용해도 풍속과 출력이 1:1로 대응하는 함수로써 하나의 풍속 값에는 하나의 출력 값만 존재한다. 하지만, figure 5-2와 같이 실제로는 동일한 풍속 또는 동일한 출력 값이라도 1:N 대응 함수와 같이 다수의 경우의 수가 존재한다. 즉, 출력곡선은

IEC 61400-12-1에 의거하여 평균 풍속에 대응하는 평균 출력 값을 제공하고 이 평균 값들에 대한 불확도를 제공한다. 따라서 평균값에 따른 불확실성은 제공하지만, 출력 곡선을 사용함에 있어서 데이터가 산포특성을 나타내는 불확실성은 제공하지 않고 있다.

본 연구에서는 출력곡선을 하나의 함수로 생각하고 있으며, 이 함수를 사용할 경우 발생할 수 있는 데이터의 산포도를 나타내기 위한 변동성을 평가하였다. 이 점이 JCGM에서 언급하는 측정 불확도와 다른 점임을 언급하고자 한다. 즉 공학에서 사용되는 모든 함수 및 모델들은 오차를 내포하고 있으므로 추정된 값에는 실제 값과 다를 수 있는 불확실성을 내포한 것으로 볼 수 있다.

MCS의 수행절차는 확률변수를 정의하고 정의된 확률변수에 대한 확률분포를 선택한다. 최종적으로 선택된 확률분포를 기준으로 난수를 발생하여 결과물에 대한 통계량을 계산한다. 본 연구에서는 발전량 예보에 대한 변동성을 추정하고자 함으로 확률변수는 변동성 요소를 의미한다.

발전량 예보에 영향을 주는 변동성 요소는 WRF 모델에서 내포하는 풍속 변동성과 풍속을 출력량으로 산출해 주는 출력곡선에 대한 변동성을 선택하였다. 출력곡선의 변동성은 다시 풍속에 따른 출력변동성과 공기밀도에 대한 변동성으로 분류하였다.

선택된 변동성 요소들의 모형은 figure 5-3와 같다. 예보된 풍속자료가 입력되면 첫 번째로 WRF 모델에 대한 변동성을 평가한다. 여기서 정의된 확률분포는 정규분포로 입력된 풍속 값을 기준으로 정규분포를 따르는 풍속변동이 추가된다. WRF model uncertainty의 과정을 통해 도출된 확률분포는 wind to power model을 통해 변동성 정보가 추가로 더해진다. 앞서 언급한 바와 같이 wind to power model은 variation of power production과 variation of air density로 분류되어 variation of power production에서 도출된 확률분포와 variation of air density에서 도출된 확률분포를 결합하여 반영한다. 여기서 variation of power production는 정규분포로 정의했고, variation of air density는 균등분포로 정의했다. 각 변동성 요소에서 산출되는 과정 및 검증은 “5.2절 변동성 요소 및 추정”에서 자세히 다뤄졌다.

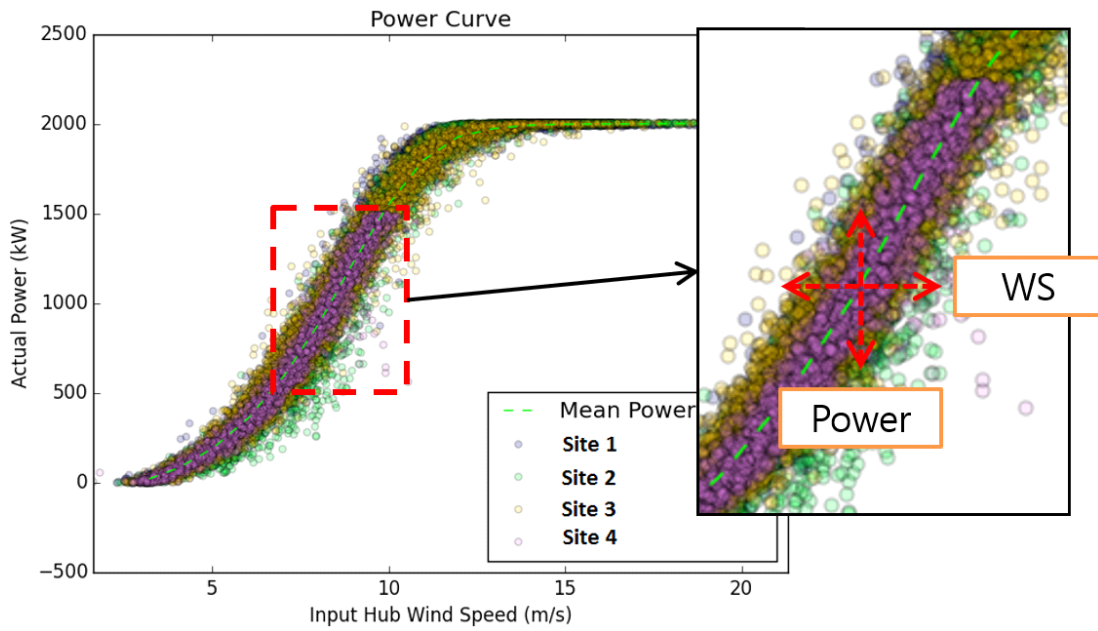


Fig. 5-2 data set of power production and power curve. (source : Peter Stuart, Andy Clifton, PCWG-share-01 Current Status, PCWG 2016)

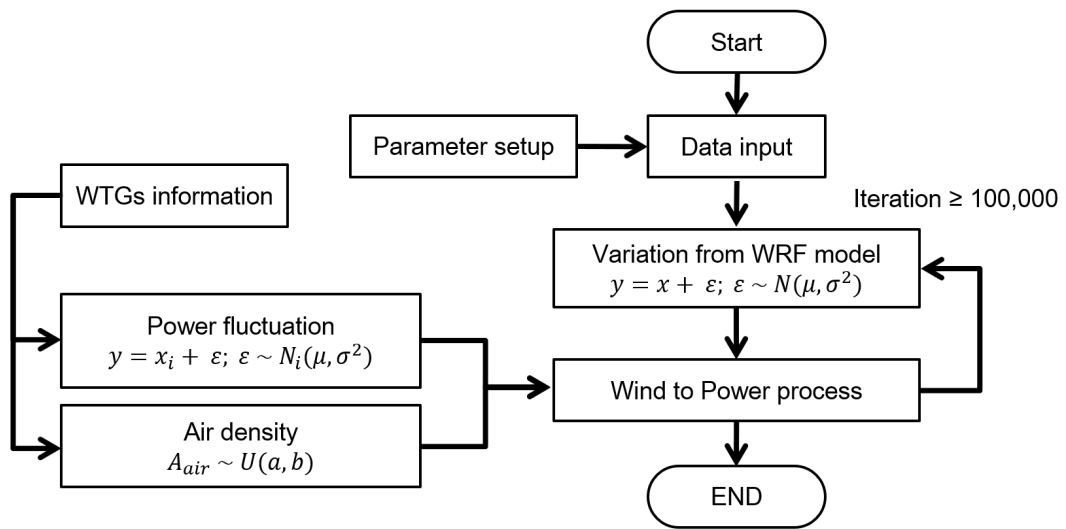


Fig. 5-3 MCS process for the variation of the wind power forecasting.

5.2. 변동성 요소 및 추정

5.2.1. WRF 모델의 풍속 변동성 평가

WRF 모델은 중규모 모델로 global model에서 제공하는 기상자료를 사용한다. 이로 인해 입력된 초기 및 경계조건에 의해 예보된 결과를 달라진다. 또한, WRF 모델에서 채용하고 있는 scheme들에 따라 사용되는 물리방정식이 달라지고, 예보된 결과도 다르게 도출된다. 여러 기상정보들 중 풍속은 출력과 가장 밀접하게 관련된 요소로써 WRF 모델에서 예보된 풍속에 대한 변동성을 평가하고자 한다.

MCS를 통해 풍속에 대한 변동성을 추정하기 위해서 WRF 모델에서 예보된 자료를 실측데이터와 비교하였다. 2010년도에 수집된 17개 AWS자료와 제주도를 대상으로 수행된 WRF 예보자료를 서로 비교하였다. 비교 결과는 figure 5-1에 도시화하였다. 오차는 RMSE(Root Mean Square Error)를 사용하였다.

제주도 전역을 대상으로 서귀포 지점이 가장 낮은 1.67 m/s로 나타났으며, 유수암 지점이 가장 높은 3.82 m/s로 나타났다. 주로 연안에 가까이 위치할수록 RMSE가 다소 낮았고, 지형 경사도가 존재하는 내륙일수록 RMSE가 다소 높았다. 이는 WRF 모델이 지형자료를 모델화하면서 발생하는 오차라고 판단된다. WRF 모델은 입력된 지형자료를 WRF 모델에서 설정된 수평해상도에 맞춰 재구성한다. 재구성된 지형자료는 격자별로 동일한 지형높이를 나타내게 되는데 실제 지형은 산맥 등에 의해 굴곡이 존재하는데 이 굴곡이 한정된 수평해상도에 의해 표현이 안 된다. 이로 인해 연안보다 지형도가 복잡한 내륙이 오차가 더 높았다고 판단된다.

연구대상인 행원풍력3호기는 제주도의 북서쪽 지역에 위치해 있고, 바다와 인접해 있는 연안지역으로 볼 수 있다. 이 위치에 대한 RMSE를 평가하여 반영할 수 있지만, WRF 모델의 특정지점에 대한 변동성을 반영하지 않고, 제주도 전체 구역에서 발생할 수 있는 변동성을 반영하여 일반적인 변동성이 평가되도록 제주도 전역에서 평가된 RMSE를 평균화하여 반영하였다. 반영된 값은 2.61 m/s로 변동성 평가 때 반영했다. 확률분포는 정규분포로 선택했고, 정규분포의 평균값은 0 m/s이고, 표준편차는

2.61 m/s로 선택하였다.

WRF 모델의 풍속 변동성은 자료의 오차분포를 반영할 수 있다. 오차분포는 예보자료와 측정자료의 차이를 나타낸 분포도로 충분한 자료가 수집되어 분포도를 구성하면 신뢰성 있는 변동성을 평가할 수 있다. 이 대안으로 존재하는 지표가 RMSE이다. RMSE는 예보값과 측정값의 차이를 합한 다음에 제곱하여 평균을 한 후 제곱근으로 취한 값이다. 이는 오차분포를 정규분포로 가정할 경우 오차분포의 표준편차와 유사하다. 즉, RMSE를 오차분포의 표준편차로 가정하여 변동성을 평가할 수 있다. 그러나, 오차분포의 평균값은 RMSE에 내포되지 않으므로, 평균오차에 대한 차이는 존재한다.

오차분포의 표준편차가 RMSE와 비슷함을 식(5-1~5-3)을 통해 증명하였다. 여기서, E는 예보 값과 측정값의 오차이고, S는 예보 값, O는 측정값을 의미한다. 이 증명은 오직 오차의 평균이 0에 가까운 값이 도달해야 성립한다.

$$SD = \sqrt{\frac{1}{n} \sum_{i=1}^n (E_i - \bar{E})^2} \tag{5-1}$$



Fig. 5-4 The RMSE results from data sets collecting from AWS in 2010

$$SD = \sqrt{\frac{1}{n} \sum_{i=1}^n [(S_i - O_i) - \overline{S_i - O_i}]^2}, \text{ if } E = S - O \quad (5-2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_i - O_i)^2}, \text{ if } \bar{E} \cong 0 \quad (5-3)$$

5.2.2. 출력변동 및 공기밀도에 의한 풍력발전량 변동성 평가

출력곡선은 풍속을 출력으로 변환해주는 척도로써, 국제표준(IEC 61400-12-1)에 따라 실증단지에서 측정되며, 복잡지형 및 이웃하는 풍력터빈으로부터의 영향이 완전히 제거된 풍력터빈 고유의 출력성능을 대표한다. 그러나 국제표준에 의해 보증된 출력곡선을 이용하여 계산된 발전량 예측 계산결과는 측정결과와 서로 차이를 보일 수 있다(Hayes et al., 2011). 이러한 차이는 출력량의 변동성에 의해 발생하며 국제표준에 명시된 방법에 따라 추정될 수 있다.

풍력터빈 출력은 풍속의 3승에 비례하기 때문에 비선형적 특성을 보인다(Soman et al., 2010). Kim and Hyun(2010)은 국제표준에 따라 계산된 출력곡선의 불확도 값이 풍속구간별로 다르게 나타난다는 결과를 제시한바 있으며, 따라서 풍속과 출력곡선의 불확도 또한 비선형적 관계임을 알 수 있다. 비선형적인 관계를 가지는 불확도 요소들을 평가하기 위해서는 MCS의 적용을 권장하고 있다(BIPM et al., 2008)(Couto et al., 2013).

Kwon(2010)은 MCS 기법을 적용하여 wind energy potential에 대한 불확도 평가를 수행하기 위해 출력곡선의 불확도를 고려하였다. 출력곡선의 불확도를 추정하기 위해서 측정된 풍속과 출력데이터를 이용하여 풍력터빈 출력곡선의 불확도 추정 식을 제안한바 있다. Kwon이 제안한 추정 식은 특정 풍력터빈에서 측정된 데이터에 근거하 실험식이기 때문에 풍력터빈 용량 및 type이 변경될 경우에는 적용타당성에 대한 검증이 필요하다. 또한, 정격풍속 이상 조건에서의 불확도를 정격출력의 0.1배로 정의하기 때문에 대형 풍력터빈의 불확도를 과대 추정하는 문제가 발생할 수 있다. 이후,

Jung et al.(2013)은 이러한 문제점을 보완하기 위해 보정계수($1/\sqrt{6}$)를 적용한 수정식을 제안하였으나, 정격출력이 높은 경우에는 여전히 보수적으로 추정하고 있다.

풍력터빈 출력곡선의 비선형성을 고려한 불확도 계산을 위해 MCS 기법을 적용하고 있으나, 풍력단지에서 측정된 풍속 및 출력데이터 또는 특정 type의 풍력터빈에 한정된 실험식을 사용해야 하는 문제점이 있다. 따라서 본 연구에서는 이러한 문제점을 보완하기 위해 측정데이터에 의존하지 않고, 풍력터빈의 type 변경 시에도 범용적인 적용이 가능한 새로운 변동성 추정 식을 제안하고자 한다.

변동성 추정 이론(Her et al., 2017)

Jung 등이 제안한 불확도 추정 식은 measured power curve의 풍속구간별 표준편차($\sigma_P(V)$)와 평균출력(\bar{P})의 비로 정의되는 CV(Coefficient of variation) 값에 보정계수($1/\sqrt{6}$)를 도입하여 식(5-4)와 같이 정의된다. 식(5-4)에서 불확도 값은 평균출력의 변화에 따라 결정된다. 또한, 특정 풍력터빈의 측정데이터에 근거하여 정의된 실험식이 다른 type의 풍력터빈에 적용될 경우, 유효성 검증이 필요하다. 따라서 본 연구에서는 이러한 단점들을 보완하기 위한 풍력터빈의 비선형적 출력변동성과 범용성을 고려한 출력곡선 변동성 추정 식을 제시하고자 한다. 이를 위해 변동성 추정 이론을 성립하였다.

$$\sigma_P(V) = \begin{cases} \left[-\frac{0.35(V - V_{rated})}{V_{rated} - V_{in}} + 0.1 \right] \frac{\bar{P}(V)}{\sqrt{6}}, & V_{in} \leq V \leq V_{rated} \\ 0.1 \frac{\bar{P}(V)}{\sqrt{6}}, & V_{rated} < V \end{cases} \quad (5-4)$$

Figure 5-5는 Kim and Hyun(2010)과 국제표준(IEC 61400-12-1), NREL 보고서(Mendoza et al., 2015)에서 제시된 풍력터빈의 출력곡선 불확도를 나타내었다. 풍력터빈의 type이 서로 다르기 때문에 정량적인 값이 정확하게 일치하지는 않지만, 정성적인 변화추세는 풍속변화에 따라 유사하게 보인다. 따라서 피치제어형 풍력터빈은 type에 상관없이 figure 5-5와 유사한 형태의 불확도 추세를 보인다고 가정할 수 있다.




Fig. 5-5 Comparison of power curve uncertainty in pitch-controlled wind turbine from IEC 61400-12-1, Kim and Hyun, NREL report. the ratio means that the combined standard uncertainty at each wind speed bin divided by the maximum combined standard uncertainty among wind speed bins.

Figure 5-6에 풍속변화에 따른 Vestas-V90 3.0MW 풍력터빈의 출력 변화량을 나타내었다. 시동풍속, 정격풍속, 정지풍속은 각 4 m/s, 15 m/s, 25 m/s이고, 정격풍속 이하의 구역에서는 토크제어를 수행하여 출력을 극대화하고, 정격풍속 이상의 구역에서는 피치제어를 실시하여 일정한 출력을 유지한다. figure 5-5와 figure 5-6을 살펴보면, 정격풍속 이전 구역에서의 출력곡선 불확도는 출력 변화량에 따라 증가 또는 감소하는 추세를 보인다. 또한, 출력변화가 거의 발생하지 않는 피치제어구간에서는 불확도 값이 일정한 추세를 보이고 있고 이와 마찬가지로 출력변화량도 일정한 추세를 보이고 있다. 즉, 출력 변화량과 불확도 값은 서로 정성적으로 밀접한 관계라고 볼 수 있다.

Figure 5-7는 정격풍속 이하에서 출력변화율의 정의를 보여준다. $P(V_L)$ 과 $P(V_H)$ 는 V_L 과 V_H 풍속에서 얻을 수 있는 평균 출력 값이다. 출력곡선은 대부분 1 m/s 간격으로 풍속 대비 출력을 제시함으로 V_L 와 V_H 의 풍속차이는 1 m/s이며, $P(V_O)$ 는 $P(V_H)$ 와 $P(V_L)$ 의 중간 값이다. 정격풍속 이하에서는 출력이 거의 선형적으로 변화하기 때문에 $P(V_H)$ 와 $P(V_L)$ 의 차이를 이용하여 기울기($\Delta P/\Delta V$)를 계산할 수 있




Fig. 5-6 The amount of variation for power production in Vestas-V90 3.0MW wind turbine.




Fig. 5-7 Definition of maximum power fluctuation rate under the rated wind speed.

다. 이는 1 m/s 이내의 풍속범위에서 변화 가능한 출력 값의 최대치이므로 특정 풍속 구간에서의 출력변화는 $P(V_0)$ 를 중심으로 최대 $\pm \Delta P/2\Delta V$ 만큼 변화한다고 볼 수 있다.

대부분의 풍력터빈은 풍속이 변화함에 따라 특정 목표출력을 생산하도록 제어된다. 외부환경 및 운전조건에 따라 미소한 출력변화가 존재할 수 있으나, 대부분의 경우에는 풍속 빈 구간별로 설정된 출력을 발생시킨다. 이러한 풍력터빈의 기계적 특징을 systematic error로 정의하였으며, 출력변화의 최대·최소 값이 $\pm \Delta P/2\Delta V$ 이고, 중심 값이 $P(V_0)$ 인 조건은 삼각분포의 형태로 표현이 가능하다. 반면에 정규분포는 삼각분포와 달리 최대 및 최소값이 분명하게 정해질 수 없기 때문에 추가적인 random error를 발생한다. 따라서 풍력터빈의 잠재적인 기계 및 제어특성에 의한 출력변화 오차를 보수적으로 추정하기 위해 변동성은 정규분포를 따른다고 정의하였다.

상기 언급한 가정 및 사실들을 정리하여 출력곡선의 변동성 추정 식의 제안을 위해 다음과 같이 가정하였다.

- 1) 출력곡선은 풍력터빈의 고유한 출력성능을 나타내는 대표적인 지표이다.
- 2) 변동성은 토크제어 구간과 피치제어 구간으로 구분된다.
- 3) 변동성은 출력곡선의 출력변화율과 유사하다.
- 4) 피치제어형 풍력터빈은 형식에 상관없이 동일한 변동성 추세를 보인다.
- 5) 제어 시스템에 의해 변동하는 출력은 정규분포를 따른다.

5가지의 가정들을 통해 변동성을 추정하는 이론식은 식(3-11)과 같다. 식(3-11)은 제어조건에 따라 2개의 풍속구간으로 구분하였고, 피치제어를 수행하는 풍속구간은 변동성 값이 일정하게 유지되는 사실을 통해 정격풍속에서 산출된 변동성 값을 정지 풍속까지 동일하게 정의하였다. $1/\sqrt{6}$ 은 삼각분포를 정규분포의 표준편차로 환산하기 위해 적용한 값이다. 식(5-5)은 분모에 풍속, 분자에 출력으로 정의되어 있어서 풍속 변화에 따른 출력변화율로 정의된 식으로 볼 수 있다. 즉, 식(5-5)은 풍속이 1m/s 변화할 때 발생할 수 있는 풍속변동에 따른 출력곡선 변동성을 추정하는 식이다.

$$\sigma_P(V) = \begin{cases} \frac{\Delta P_i}{2\sqrt{6}\Delta V_i}, & V_{in} \leq V_i < V_{rate} \\ \frac{\Delta P_{rate}}{2\sqrt{6}\Delta V_{rate}}, & V_{rate} \leq V_i \leq V_{out} \end{cases} \quad (5-5)$$

출력은 공기밀도에 의해 변함으로 국제표준에서도 공기밀도를 실증단지에서 측정된 공기밀도로 산출하지 않고, 표준공기밀도인 1.225 kg/m^3 으로 표준화한다. 국제표준은 공기밀도의 표준화 과정을 수행한 후 공기밀도에 대한 불확도를 평가한다. 이 사실을 통해 공기밀도는 출력곡선의 변동성 요소로 선정할 수 있다.

공기밀도의 변동에 대한 출력곡선을 산출하기 위해 국제표준에서 제시한 공기밀도를 정규화 하는 식(5-6)을 이용하여 공기밀도에 따라 출력곡선의 변동 범위를 산출하였다. 여기서 V_0 는 표준 공기밀도에서의 풍속이고, ρ_0 는 표준 공기밀도이다. ρ_{site} 는 사이트에서 측정된 공기밀도이고, V_{site} 는 ρ_{site} 에 해당하는 풍속을 의미한다.

$$V_{site} = V_0 \left(\frac{\rho_0}{\rho_{site}} \right)^{1/3} \quad (5-6)$$

Figure 5-8에 공기밀도에 따라 도출된 출력곡선을 예시로 나타냈다. Figure 3-11는 식(3-12)으로부터 공기밀도에 따라 보정된 풍속을 구하고, 보정된 풍속에 따른 출력을 출력곡선으로부터 산출하여 도출된 그림이다. 예시로 최소 공기밀도는 표준 공기밀도 1.225 kg/m^3 으로부터 -0.1 kg/m^3 낮아진 1.125 kg/m^3 이고, 최대 공기밀도는 표준 공기밀도 1.225 kg/m^3 으로부터 $+0.1 \text{ kg/m}^3$ 높아진 1.325 kg/m^3 이다. 풍력터빈은 행원풍력 3호기인 Vestas V47-660kW이다.

공기밀도는 균등분포를 따른다고 알려져 있다(Kim, 2010)(Jung et al., 2013). 따라서 공기밀도에 의해 변동하는 출력 값도 균등분포를 따른다고 할 수 있다. 균등분포는 하한 값에서 상한 값까지 동일한 분포를 보여주는 분포도이다. 이 분포도를 따르는 변동성은 균등분포의 반너비(상한 값 - 하한 값)에서 $\sqrt{3}$ 으로 나눈 값이다. Figure 5-8에서 보이듯이 식(5-6)으로부터 공기밀도 최대 및 최소 값에서의 출력곡선이 도출




Fig. 5-8 The power curve at maximum and minimum air density in Vestas V47-660kW. (max. air density : 1.325 kg/m³, min. air density : 1.125 kg/m³)




Fig. 5-9 Summary of the uniform distribution.




Fig. 5-10 The pseudo-random data set using MCS in Vestas V47-660kW with variation of air density and wind speed fluctuation. (max. air density : 1.325 kg/m^3 , min. air density : 1.125 kg/m^3)

되어 출력의 최소 및 최대값이 구해지고, 도출된 최소 및 최대값으로부터 반너비를 산출하고 $\sqrt{3}$ 으로 나누어 변동성을 산출한다(figure 5-9). 산출된 값은 1σ 에 해당되는 변동성이다.

상기 언급한 출력곡선의 변동성 요소는 풍속변동과 공기밀도이다. 이 2개의 변동성 요소들은 출력곡선과 연관되어 있으므로 2개의 변동성들을 합성하였다. 이를 JCGM 101:2008에서는 합성불확도라고 부른다. 합성불확도는 불확도 요소들이 서로 상관관계가 없을 경우 식(5-7)과 같이 계산된다. $\partial f/\partial x_i$ 는 감도계수로 불리며 변수인

x_1, x_2, \dots, x_N 의 값이 변할 때 추정값 y 가 얼마나 변화하는지를 나타낸다. 또한, 불확도 요소들의 단위가 서로 다를 경우에 평가대상인 불확도의 단위로 환산해준다.

$$u_c^2(y) = \sum_{i=1}^N \left[\frac{\partial f}{\partial x_i} \right]^2 u^2(x_i) \quad (5-7)$$

공기밀도는 오직 온도와 압력을 독립변수로 사용하는 값이다. 그러므로 공기밀도와 풍속변동은 상호독립적이라고 가정하여 식(5-7)을 도입하여 합성불확도를 산출할 수 있다. 또한, 앞에서 진술한 바와 같이 불확도 요소들의 평가결과는 출력량이므로 감도계수 $\partial f/\partial x_i$ 는 1이 된다. 따라서 공기밀도와 풍속변동의 합성불확도는 식 (5-8)와 같이 된다. 식(5-9)은 공기밀도의 변동성을 구하는 식이다. 식(5-8, 5-9)에서 산출되는 변동성은 표준불확도로 1σ 에 해당되는 변동성이다.

$$u_{c,i}^2(y) = \sqrt{\sigma_P(V_i)^2 + \sigma_P(\rho_i)^2} \quad (5-8)$$

$$\sigma_P(\rho_i) = \frac{(P_{\max}(V_i) - P_{\min}(V_i))}{2\sqrt{3}} \quad (5-9)$$

Vestas V47-660kW를 대상으로 식(5-5, 5-8, 5-9)을 이용한 결과를 figure 5-10에 나타내었다. Figure 5-10에서 도시화된 데이터는 공기밀도와 풍속변동에 대한 변동성 데이터가 포함되었고 MCS를 이용해 무작위 난수를 발생하여 생성한 데이터이다.

변동성 추정식의 유효성 검증(Her et al., 2017)

본 연구에서 제안된 풍력터빈의 출력곡선 변동성 추정 식(5-5)에 대한 유효성을 검증하기 위해 식(5-4, 5-5)을 적용한 MCS 기법을 이용하여 Vestas-V90 3.0MW의 출력 데이터를 예측하였으며, 실제 상업발전단지에서 측정된 출력데이터와 비교하였다. 비교대상 풍력터빈의 출력데이터는 한국남부발전(주)에서 운영 중인 제주 한경풍력발전단지(21MW)에 설치된 Vestas-V90 3.0MW 풍력터빈에서 수집되었다. 측정데이터의 신뢰성확보를 위해 국제표준(IEC61400-12-1)에 규정된 유효방위각 범위 내에서만 측정




Fig. 5-11 Estimating for the standard deviation of power production. Jung approach means estimating for std. using eq.(5-4), present study means estimating for std. using eq.(5-5).

된 데이터를 사용하였으며, 풍력터빈 출력이 '0' 인 데이터와 종단풍속 근방에서 발전을 중단한 후 재가동된 측정데이터는 제외하였다.

Figure 5-11에 식(5-4)과 식(5-5)을 이용하여 계산된 표준편차 값과 측정 출력데이터를 이용하여 계산된 표준편차 값의 비교결과를 나타냈다. 식(5-4)과 측정데이터를 이용한 표준편차 계산결과는 서로 잘 일치하지 않으며 정격풍속이상에서 약 110 kW 이상의 큰 차이가 나타난 반면, 식(5-5)에 의해 계산된 값은 상대적으로 작은 차이(50 kW)를 보였다. 또한 측정 결과와 식(5-5)에 의해 계산된 결과의 최대 표준편차 발생 구간(9~11 m/s)은 서로 잘 일치하고 있으나, 식(5-4)을 이용한 계산결과는 11~13 m/s에서 나타나고 있다. 따라서 본 연구에서 제안된 변동성 추정 식을 이용하여 계산된 출력곡선 변동성 값이 상대적으로 더 잘 일치한다고 판단된다.

Figure 5-12와 figure 5-13에 풍속 10 m/s와 12 m/s 구간에서 측정된 출력데이터 분포와 식(5-4)와 식(5-5)로부터 각각 추정된 정규분포를 나타냈다. 식(5-4)을 이용한 정




Fig. 5-12 The normal distribution of Present study and Jung approach results in Vestas V90 3.0 MW at 10 m/s wind speed bin.




Fig. 5-13 The normal distribution of Present study and Jung approach results in Vestas V90 3.0 MW at 12 m/s wind speed bin.




Fig. 5-14 Estimated data obtained through MCS and measured data in Vestas V90-3.0 MW. Estimated data is created from eq.(11) without the variation of the air density.

규분포 추정결과는 측정데이터가 존재하지 않는 출력발생 구간까지 과도하게 포함하고 있기 때문에 특히 정격풍속 이후에서의 표준편차를 과대 추정하는 것으로 판단된다. 반면, 식(5-5)의 정규분포 추정결과는 측정데이터의 상대도수가 3% 이하인 구간을 추정하지 못하는 대신, 측정데이터가 평균출력발생구간에 집중되는 특성을 잘 반영하고 있다. 즉, 식(5-4)은 풍력터빈의 출력변화 범위를 폭 넓게 고려하기 때문에 표준편차를 과도하게 예측하고 있는 반면, 식(5-5)은 토크 및 피치제어에 의해 특정 풍속조건에서의 출력변화가 평균출력에 집중되는 특징을 잘 반영하고 있기 때문에 상대적으로 더 우수한 예측 정확도를 보이는 것으로 판단된다.

본 연구에서 제안된 식을 이용하여 풍속변화에 따른 출력산포도의 구현을 위해서 MCS를 수행하였으며 측정된 출력산포도와 비교하였다. MCS를 수행하기 위해서는 확률밀도함수의 정의가 필요하다. 진술한 바와 같이 현대식 대형 풍력터빈들은 대부분 토크제어와 피치제어에 의해 모든 풍속조건에서 특정 목표출력을 발생시킬 수 있도록 제어되므로, 본 연구에서는 확률밀도함수로서 additional random error를 포함하는 정규분포를 사용하였다. 개별 풍속조건에서의 정규분포 평균값은 출력곡선에서 제시

된 출력 값을 적용하였고 표준편차는 식(5-5)을 이용하여 계산된 값을 적용하였다. 시뮬레이션 결과의 검증을 위해 비교된 측정데이터는 외부환경으로부터의 영향이 완전히 제거된 바람 및 출력데이터를 사용하였기 때문에 풍력터빈의 고유 변동성만 반영된 결과라고 볼 수 있다.

Figure 5-14에 MCS에 의해 예측된 출력산포도와 측정된 출력산포도의 비교결과를 나타냈으며, 두 결과가 모든 풍속조건에서 매우 잘 일치하고 있기 때문에 출력곡선의 변동성 추정을 위한 식(5-5)의 유효성이 충분히 검증되었다고 판단된다.

실시간 발전량 예측 및 변동성 평가

풍력단지의 발전계획수립 및 전력설비관리를 위한 EMS(Energy Management Systems)의 효율적인 운용을 위해서는 풍력터빈의 실시간 발전량과 변동성 예측이 필요하다(Yang et al., 2016). 그러나 출력곡선은 특정 풍속조건에서의 평균출력을 대표하기 때문에 변동성 예측에 적용될 수 없다. 출력곡선의 변동성 정보는 풍력터빈의 제작사가 국제표준에 의해 보증된 불확도를 제공한다. 하지만, 출력곡선의 불확도는 풍력터빈의 고유 특성이 내포되어 있으므로 비공개하는 경향이 존재한다. 따라서 실시간 발전량 예보분야에서 풍력터빈의 출력 변동성을 평가하기 위해서는 풍력터빈 type에 상관없이 약 3~5%의 변동성 값을 일괄적으로 적용하기도 한다.(Yan et al., 2015)(Alessandrini et al., 2015)

본 연구에서는 실시간 풍력발전량 예보 시스템의 구축을 위하여 개발된 식(5-5)을 적용하여 예보 시스템의 적용 가능성을 살펴보고자 한다. 풍력발전량 예보 시스템은 기상수치모델을 이용하여 풍속을 예보한 다음에 출력을 예보한다. 하지만, 기상수치 모델에는 모델 자체의 불확실성을 내포하고 있기 때문에 이를 제거하기 위해서 측정 데이터를 가지고 출력량을 예보하였다.

Figure 5-15에 식(5-4)과 식(5-5)에서 도출된 변동성 예보와 측정데이터를 도시화하였고, 보다 엄밀한 비교검증을 위해 인접한 풍력터빈으로부터의 후류영향을 받지 않는 조건에서 측정된 발전량 데이터를 비교대상으로 사용하였다. Figure 5-15에 나타난 발전량의 변동성 범위는 $\pm 3\sigma$ (99.7%)로 계산되었으며 $+3\sigma$ 은 풍력터빈의 최대발전량, -3σ 은 최소발전량을 의미한다. 식(5-4)에 의해 추정된 변동성 범위가 식(5-5)에 비해 크게 나타남을 육안으로 확인 할 수 있다. 특히 정격풍속이상에서 과도한 변동




Fig. 5-15 Forecasting for wind power production and measured power production with the predicted variation($\pm 3\sigma$).

성 범위(2628~3444 kW)를 예보하고 있다.

변동성은 점 추정이 아니고 특정 값의 변동범위를 나타내기 때문에 발전량 예보 값과 직접적인 비교는 불가능하다. 따라서 MCS에 의해 변동성 범위 내에서 발생 가능한 임의의 발전량을 계산한 후 이를 측정된 발전량과 비교하였다. 확률밀도함수는 언급한 정규분포를 선택하였고, 평균값은 출력곡선의 풍속구간별 평균출력 값을 표준 편차는 식(5-4)과 식(5-5)에서 추정된 값을 각각 사용하였다. 10분 간격으로 예측된 출력 값들을 1 case로 설정하고 각 case별로 예보 정확도를 평가한 후 그 결과값들을 평균하였으며, 평균된 예보 정확도 결과가 완전히 수렴될 때 까지 MCS를 100,000회 반복하였다. Figure 5-15에 나타난 측정된 발전량과 변동성이 고려되지 않은 예측된 발전량의 차이는 단순히 출력곡선에 의해서만 발생하는 오차이다. 이를 reference case로 정의하였다.

MCS에 의해 풍력 발전량 예보정확도 결과들을 Table 5-1에 나타내었다. Case A는 식(5-4)을 적용한 결과이며 Case B는 식(5-5)을 적용한 결과이다. Reference case의 경우, $V_{in} \leq V < V_{rate}$ 구간에서 MAE와 RMSE가 각각 81.0 kW와 102.9 kW로 나타났으며, $V_{rate} \leq V \leq V_{out}$ 구간에서는 26.4 kW(MAE)와 28.2 kW(RMSE)로 낮은 오차를 보였다. 정격 풍속 미만의 조건에서는 이론적인 풍력터빈 출력변동범위가 0 kW ~ 3,000

Table 5-1 Prediction accuracy of power production according to MCS. Reference case: measurement data versus predicted data using the power curve, case A: measurement data versus predicted data obtained using MCS based on (10), case B: measurement data versus predicted data obtained using MCS based on (11). *() means the difference between the results of reference case and the results of case A and case B.

Reference Case			
Wind Speed Range	$V_{in} \leq V < V_{rate}$	$V_{rate} \leq V \leq V_{out}$	$V_{in} \leq V \leq V_{out}$
MAE [kW]	81.0	26.4	76.8
NMAE [%]	2.7	19.3	2.5
RMSE [kW]	102.9	28.2	99.2
NRMSE [%]	3.4	20.6	3.3
Case A			
Wind Speed Range	$V_{in} \leq V < V_{rate}$	$V_{rate} \leq V \leq V_{out}$	$V_{in} \leq V \leq V_{out}$
MAE [kW]	131.8(+50.8)	100.2(+73.8)	129.3(+52.5)
NMAE [%]	4.3(+1.6)	73.2(+53.9)	4.2(+1.7)
RMSE [kW]	175.6(+72.7)	125.6(+97.4)	172.2(+73)
NRMSE [%]	5.7(+2.3)	91.8(+71.2)	5.6(+2.3)
Case B			
Wind Speed Range	$V_{in} \leq V < V_{rate}$	$V_{rate} \leq V \leq V_{out}$	$V_{in} \leq V \leq V_{out}$
MAE [kW]	92.8(+11.8)	26.4(+0.0)	87.5(+10.7)
NMAE [%]	3.0(+0.3)	19.3(+0.0)	2.9(+0.4)
RMSE [kW]	120.8(+17.9)	28.4(+0.2)	116.2(+17.0)
NRMSE [%]	4.0(+0.6)	20.8(+0.2)	3.8(+0.5)




Fig. 5-16 MAE results from measured power data and predicted power data obtained through MCS.

kW이며, 일정한 출력제어를 실시하는 정격풍속 이상의 조건에 비해 매우 크다. 따라서 정격풍속 이상의 구간에서의 NMAE(19.3%)와 NRMSE(20.6%)가 정격풍속 이하의 구간에 비해 각각 +16.6%(2.7%), +17.2%(3.4%)만큼 크게 나타났다. 풍력터빈의 전체 운전 풍속구간($V_{in} \leq V \leq V_{out}$)에서는 MAE와 RMSE가 각각 76.8 kW, 99.2 kW, NMAE와 NRMSE는 각각 2.5%, 3.3%로 나타났다. 이는 Taslimi-Renani et al.(2016)들이 도출한 연구결과(1.57% ~ 6.85%)와 유사한 수준으로 보여졌다. 따라서 본 연구에서의 변동성 추정결과들은 reference case 값에 근접할수록 잘 추정된 것으로 볼 수 있다.

Case A 결과의 경우, $V_{in} \leq V \leq V_{out}$ 조건에서 Case B에 비해 상대적으로 큰 오차를 보이고 있다. 특히 Case B의 MAE(26.4 kW) 값은 $V_{rate} \leq V \leq V_{out}$ 의 조건에서 reference case와 잘 일치하는 반면, Case A의 MAE(100.2 kW)는 과대 예측하는 결과를 보인다. 식(5-4)의 경우 정격풍속이상의 조건에서 평균출력의 $0.1/\sqrt{6}$ 배를 변동성 값으로 적용하기 때문에 정격풍속이 높은 대형풍력터빈 발전량에 대한 변동성을 과대 예측하는 것으로 판단된다.

Figure 5-16에 0.5 m/s 간격으로 측정된 Vestas V-90의 출력과 MCS에 의해 예측된 출력의 MAE 비교결과를 나타냈다. Case B의 경우 전 범위 풍속구간에서 측정데이터

와 잘 일치하는 반면 Case A는 8 m/s 이후의 풍속구간에서 잘 일치하지 않는 결과를 보였다. Table 5-1에 제시한 결과와 마찬가지로, 정격풍속 이상의 조건에서 Case A의 오차가 크게 나타나고 있으며, 정격풍속 이하의 조건에서는 8 m/s ~ 15 m/s 구간에서 큰 오차를 보였다. Case B의 경우 측정데이터와 최대 약 22 kW의 오차범위 내에서 잘 일치하는 결과를 보였으며, 정격풍속이상의 조건에서 측정데이터와 매우 잘 일치하는 결과를 얻었다. Case B의 결과에서 MAE가 과소평가된 풍속구간은 존재하지 않았다.

5.3. 풍력발전량 변동성 평가 결과

본 절은 4.3절 풍력발전량 예보 정확도 결과에서 제시된 발전량 데이터에 대한 변동성을 평가하였다. 변동성 요소는 5.2절 변동성 요소 및 추정에서 언급한 WRF 모델의 풍속 변동성과 출력곡선의 변동성을 선정하였다.

변동성을 평가하기 위한 MCS 절차는 figure 5-3와 같이 WRF 모델의 풍속 변동성을 첫 번째로 적용하였고, 출력곡선의 변동성을 마지막으로 적용하여 풍력터빈의 출력 가능한 최소 및 최대값을 산출하였다. 변동성은 점추정이 아니고 구간추정임으로 측정된 데이터의 직접적인 비교는 불가능하다. 따라서 측정데이터가 발전량의 예보 범위에 들어오는지 판단하여 성공 및 실패를 기록하였고, 전체 데이터 중에 성공한 횟수를 백분율로 표현하였다. 여기서, 최종적으로 평가된 변동성의 범위는 정규분포를 기준으로 95% 확률 범위를 산출하였다.

중기예보에서 변동성 예보의 정확도는 76.7%가 나왔다(figure 5-17). 최소 정확도는 58.8%로 54h 예보시점에 나타났다. 최고 정확도는 94.7%로 71h 예보시점에 나타났다. 3일 동안 변동성 예보는 58.8%에서 94.7% 사이에서 정확도가 높다가 낮아지는 경향을 지속적으로 나타나고 있다. 이는 풍력터빈의 ramp 특성(Hwang et al., 2012)에 의해 오차 변화가 일관성 없이 변동하는 것으로 판단된다. 이로 인해 전체적인 경향성 또한 증가하거나 감소하는 모습은 발견되지 않았다.

장기예보에 대한 변동성 예보 결과는 figure 5-18에 일별로 나타났다. 1일 앞 예보

는 정확도가 92.6%로 가장 우수했고 7일 앞 예보부터 약 70% 대로 급격하게 줄어들었다. 최저의 정확도를 나타낸 예보일은 9일로 62.1%를 나타냈다.

상기 언급한 결과들을 종합적으로 살펴보면, 중기 예보는 3일 동안 우수한 예보 결과를 도출할 수 있으며 변동성 예보 정확도는 약 76%를 기대할 수 있다. 장기 예보는 6일 앞 예보까지 70% 이상의 정확도를 기대할 수 있고, 7일 이후 예보는 70% 수준으로 기대치가 낮게 평가된다. 따라서 장기예보에서는 7일 이후 예보에 대한 보정이 절실히 필요하다고 판단된다.

P95에 해당하는 발전량에 대한 변동성 범위를 측정된 데이터와 비교하면 최저 발전량에 근접한 경우가 존재하며(figure 5-19), 이는 변동성 범위 내에 존재했지만 예보된 평균 발전량(P50)와 비교하면 많은 차이를 육안으로 확인할 수 있었다. 하지만, 발전량의 증가 추세 또는 감소 추세를 잘 추정하는 모습도 같이 확인할 수 있었다.

초기에 측정 데이터가 예보된 P95 범위를 벗어났지만 시간이 흐름에 따라 점차 측정된 발전량과 유사하게 예보가 보정되는 경우도 존재했다(figure 5-20). 이는 비록 과도한 풍속을 예보하여 실제 발전량보다 높은 발전량이 생산된다고 예보했지만, WRF 모델에서 1시간 1번씩 경계조건이 재입력되는 과정을 통해 보정된 것으로 판단된다.

또한 예보기간 동안 측정된 데이터와 유사한 결과를 보여준 경우도 존재했다(figure 5-21). 출력이 급격하게 증가하는 현상인 ramp 발현시점을 못 맞춘 경우지만, 그 외 상황에 대해서는 잘 추정한 경우이다. 특히 ramp 발현시점은 맞지 않지만 앞으로 출력이 급격하게 변동할 상황이 존재함을 변동성을 통해 암시적으로 알 수 있었다.

하지만 과도한 변동성 범위가 존재함을 알 수 있었고(figure 5-19, 20, 21) 과도한 변동성 범위로 인해 변동성의 정확도는 높았지만 고려해야할 발전량 변동 폭이 높았음을 알 수 있었다. 또한, 변동성 예보의 정확도에 비해 점예보(point forecasting, 4.3 절 풍력발전량 예보 정확도 결과)에 대한 정확도가 상대적으로 낮았다. 이는 변동성 요소 중 하나인 WRF 모델의 풍속 변동성이 2.61 m/s로 높은 풍속오차를 반영하여 나타난 결과로 생각된다. 예를 들면 풍속이 2.61 m/s 만큼 증가하거나 감소했다면 이에 따라 풍력터빈의 발전량도 증가하거나 감소하게 된다. 이 증·감소량이 풍속에 3제곱에 해당하므로 발전량의 변동 폭이 급격하게 증가하게 된다.

WRF 모델의 풍속 변동성을 축소하려면 WRF 모델의 scheme 향상으로 인해 풍속

정확도를 높여야 한다고 생각된다. 또는 scheme에 대한 민감도 분석을 수행하여 최적화를 수행하거나, scheme별로 예보자료를 생성하여 다수의 예보자료를 서로 보완하는 방법도 필요하다고 생각한다.




Fig. 5-17 The accuracy for the variation of power production in medium-term.




Fig. 5-18 The accuracy for the variation of daily power production in long-term.




Fig. 5-19 Measured power production, predicted power production and predicted variation(P95) from 4/29 to 5/02 in medium-term.

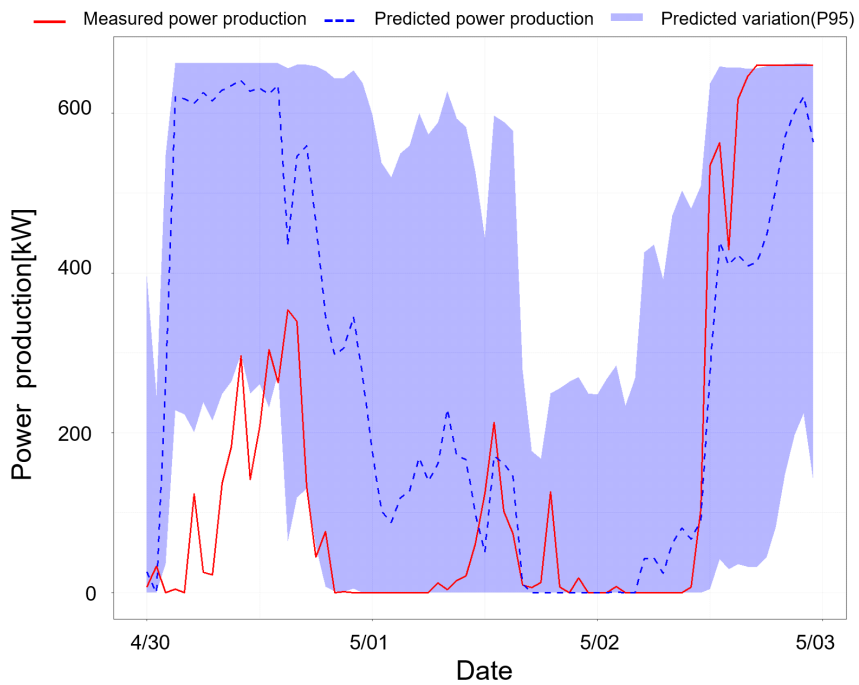


Fig. 5-20 Measured power production, predicted power production and predicted variation(P95) from 4/30 to 5/03 in medium-term.




Fig. 5-21 Measured power production, predicted power production and predicted variation(P95) from 5/01 to 5/04 in medium-term.

6. 결 론

본 연구에서는 WRF 모델을 이용한 실시간 풍력발전량 예보 시스템과 MCS를 이용한 변동성을 평가하였다. 예보 시스템을 구축하기 위해 필요한 개념설계와 상세설계를 정의하였다. 개념설계는 예보 시스템의 목적부터 시작하여 시간, 해상도, 대상, 방법을 고민하는 단계로써 상세설계를 도입하기 전에 개발자들이 개발 방향을 정립할 수 있는 틀을 제시하였다. 더욱이 기상수치모델인 WRF 모델을 사용할 경우 필수요소들을 정리했고 필수요소들에 대해서 예보 목적에 부합되도록 결정했다. 개념설계 단계를 통해 실시간 풍력발전량 예보 시스템의 전체적인 구성을 마쳤다.

상세설계 단계에서는 개념설계 단계에서 결정된 요소들을 바탕으로 하드웨어 및 WRF 모델을 설치하고 설정하였다. 설치된 하드웨어의 성능을 최대한 활용하기 위해 병렬연산에 대한 성능을 검증하고 최적의 조합을 찾았다. 이를 통해 하드웨어의 성능에 따른 예보 정확도의 한계점을 밝혔고, scheduling을 수립할 시 근거자료로 사용될 수 있는 speed ratio를 정의하였다. 뿐만 아니라 WRF 모델에서 지표면 모델에 대한 예보 정확도를 최적화하였다.

통계모델에 합리적인 도출을 위하여 풍속 및 풍향 데이터를 u-speed와 v-speed로 분해하는 과정인 UV법을 제시하였다. 회귀모델과 신경망모델에 UV법을 도입하여 풍속 및 풍향의 예보 정확도를 검토하였다. 풍속 및 풍향 데이터를 사용할 경우 편차만 고려하여 잘못된 방향으로 풍향을 조정하지만, u-speed와 v-speed를 사용할 경우 방향성을 고려하여 풍향을 조정하였다.

풍력발전량의 변동성 예보를 평가하였다. WRF 모델에 내포된 풍속 변동성과 풍력터빈의 출력곡선에 내포된 변동성을 고려하였다. WRF 모델의 풍속 변동성은 예보 지역 일대에 분포된 RMSE의 결과를 근거로 평가하였다. 출력곡선에서 풍속에 의한 변동성은 제안된 변동성 추정식을 통해 추정되었다. 제안된 변동성 추정식은 피치제어형 풍력터빈에 적합한 추정식으로 풍력터빈의 용량에 상관없이 적용할 수 있고, 제

작사의 출력곡선 정보만을 사용함으로써 쉽고 용이하게 쓰일 수 있다. 추가적으로 공기 밀도에 대한 출력곡선 변동성을 합성하여 최종적인 출력곡선 변동성을 추정하였다.

구축된 예보 시스템의 성능에 부합되는 scheduling을 수립했다. scheduling은 예보 자료를 제공해야 할 시간을 기준으로 WRF 모델의 소요시간과 GFS 자료의 업로드 및 다운로드를 고려하여 수립했다. WRF 모델에서의 시점과 현실세계의 시점의 차이를 고려하여 실시간으로 예보자료를 제공했다.

중기예보의 풍속 정확도는 MAE가 1.99 m/s, RMSE가 2.53 m/s, 발전량 정확도는 MAE가 180 kWh(27.3%), RMSE가 245.61 kWh(37.2%)로 나타났다. 예보기간동안 비슷한 수준의 예보 정확도를 보여줬다. 이를 통해 중기예보는 다가오는 풍력터빈의 운영 계획을 재점검하는 용도로 쓰일 수 있고, 작업자의 안전한 환경을 확보하는데 기초정보로 사용될 수 있다. 또한, 보수로 인해 발생하는 손실액을 잠정적으로 추정하는데 도움이 될 것이다.

장기예보의 풍속 정확도는 MAE가 2.54 m/s, RMSE가 3.39 m/s, 발전량 정확도는 MAE가 4.28 MWh(27.3%), RMSE가 5.64 MWh(36.3%)로 나타났다. 일주일을 기준으로 6일까지 발전량 정확도는 MAE 기준으로 2.79 MWh에서 3.85 MWh의 범위를 보여줬고, 7일 후 발전량 정확도는 MAE 기준으로 4.06 MWh에서 5.54 MWh의 범위를 보여줬다. 이는 고·저기압과 같은 규모가 큰 기상요소들이 한반도를 지나가는 횟수가 누적될수록 예보 오차가 점차 증가한다고 볼 수 있다. 따라서 장기예보의 1주차 예보는 타당한 정보로 볼 수 있으나, 2주차 예보는 우연히 맞는 확률이 높다고 판단되어 추가적인 보완이 반드시 필요하다.

중기예보의 변동성 예보 결과는 평균 76.7%로 예보 정확도를 나타냈다. 시간대별 예보 결과로는 3일 예보기간동안 최저 58.8%에서 최대 94.7%까지 나타났다. 장기예보의 변동성 예보 결과는 평균 80.8%로 나타났다. 일변 예보결과로는 14일 예보기간동안 최저 62.1%에서 최대 92.9%까지 나타났다. 6일까지는 평균 91.0%이고, 7일 후부터는 평균 73.2%를 보여줬다.

중기예보 및 장기예보의 변동성 예보는 point forecasting의 결과보다 높은 정확도를 나타냈다. 이는 변동성 요소 중 하나인 WRF 모델의 풍속 변동성이 과도하게 산정되어 발생한 결과이다. WRF 모델의 풍속 변동성을 저감하려면 WRF 모델의 scheme 향상으로 인해 풍속 정확도를 높여야 한다고 생각된다. 또는 scheme에 대한

민감도 분석을 수행하여 최적화를 수행하거나, scheme별로 예보자료를 생성하여 다수의 예보자료를 서로 보완하는 방법도 필요하다고 생각한다.

특히, 본 연구에서는 WRF 모델만 사용했으므로 통계모델을 추가로 도입한다면 정확도 향상을 기대할 수 있다고 생각한다. 단기예보를 수행할 경우 풍력터빈의 운영계획 뿐만 아니라 전력수립계획에 도움을 줄 수 있다. 이를 위해 기상수치모델에서의 LES 모델을 도입해야 한다. 추후 단기예보를 위해 LES 모델에 대한 연구가 활발히 진행되길 기대해 본다. 또한, 4차 산업혁명에 맞이하여 기계학습 분야가 전 세계적으로 관심을 받고 있다. 기계학습 분야가 활발히 진행된다면 기상수치모델에서 줄일 수 없는 오차들을 보완하는데 기여할 것으로 생각된다.

참 고 문 헌

- 고경남, 허종철, "풍력공학입문", 문운당, 2007.
- 고용준, 신동준, 김진오, 이호상, "경쟁 전력시장에서 발전기 유지보수계획을 고려한 입찰전략수립", 한국에너지공학회지, 11(1) 2002: 59-66.
- 기상청, "국민의 내일을 위한 동반자 보다 나은 기상청", 기상청 홍보책자, 2018
- 한국동서발전, "전력거래 핸드북", 2008.
- 한국전력거래소, "전력거래실무 핸드북", 2004.
- Afshari-Igder, M.; Niknam, T. and Khooban, M. H., "Probabilistic wind power forecasting using a novel hybrid intelligent method", *Neural Computing and Applications*, 30.2(2018): 473-485.
- Aguera-Perez, A.; Palomares-Salas, J. C.; de la Rosa, J. J. G., "Weather forecasts for microgrid energy management: Review, discussion and recommendations", *Applied Energy* 228 (2018): 265-278.
- Alessandrini, S.; Delle Monache, L.; Sperati, S. and Nissen, J. N., "A novel application of an analog ensemble for short-term wind power forecasting", *Renewable Energy* 76 (2015): 768-781.
- Bailey, B.; Brower, M.C. and Zack, J., "Short-Term Wind Forecasting," in *Proceedings of the European Wind Energy Conference EWEC 1999*, pp. 1062-1065, Nice, France, March1-5,1999.
- Bernardet, L.; Wolf, j.; Nance, L.; Loughe, A.; Weatherhead, B.; Gilleland, E.; Brown, B., "Comparison between WRF-ARW and WRF-NMM objective forecast verification scores", *23rd Conference on Weather Analysis and Forecasting/19th Conference on Numerical Weather Prediction*. Omaha, NE. Accessed June. Vol. 13. 2009.
- BIPM, I.; IFCC, I.; IUPAC, I. and ISO, O., "Evaluation of measurement data—guide for the expression of uncertainty in measurement. JCGM 100: 2008.",

Citado en las 167 (2008).

BIPM, O.; IEC; ILAC; IFCC; IUPAC; IUPAP and OIML, "Evaluation of Measurement Data—Supplement 1 to the Guide to the Expression of Uncertainty in Measurement, Propagation of Distributions Using a Monte Carlo Method", Joint Committee for Guides in Metrology, Bureau International des Poids et Mesures, JCGM101(2008).

Bremnes, J. B., "Probabilistic wind power forecasts using local quantile regression", *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology* 7.1 (2004): 47-54.

Castellani, F.; Astolfi, D.; Mana, M.; Burlando, M.; Meißner, C. and Piccioni, E., "Wind power forecasting techniques in complex terrain: ANN vs. ANN-CFD hybrid approach", In *Journal of Physics: Conference Series*, Vol. 753, No. 8, p. 082002, (2016, September), IOP Publishing.

Carobbi, C. F., "The GUM Supplement 1 and the uncertainty evaluations of EMC measurements.", *IEEE-EMC Newsletter* 2010 (2010): 53-57.

Chen, F., and Dudhis, J., "Coupling an advanced land-surface hydrology model with the Penn State NCAR MM5 modeling system. Part I: Model description and implementation", *American Meteorological Society*, 129(2001): 569–585.

Cohen, A. E.; Cavallo, S. M.; Coniglio, M. C. and Brooks, H. E., "A review of planetary boundary layer parameterization schemes and their sensitivity in simulating southeastern US cold season severe weather environments", *Weather and forecasting* 30.3 (2015): 591-612.

Costello, R.; McCoy, D.; O'Donnell, P.; Dutton, A. G. and Kariniotakis, G. N. , "Potential benefits of wind forecasting and the application of More-Care in Ireland", In *Proceedings of the 3rd MED power conference*. (2002, November).

Couto, P. R. G.; Damasceno, J. C. and de Oliveira, S. P., "Monte Carlo simulations applied to uncertainty in measurement", *Theory and Applications of Monte Carlo Simulations*. InTech, 2013.

- Cutler, N.; Jacka, K.; Nielsen, T. S. and Kay, M., "The First Australian Installation of the Wind Power Prediction Tool," in Proceedings of the Global Wind Energy Conference, Adelaide, Australia, Sept. 18–21,2006.
- Doubrawa, P.; Montornes, A.; Barthelmie, R. J.; Pryor, S. C. and Casso, P., "Analysis of Different Gray Zone Treatments in WRF-LES Real Case Simulations", Wind Energ. Sci. Discuss., <https://doi.org/10.5194/wes-2017-61>, 2018.
- Dudhia, J.; Hong, S.-Y. and Lim, K.-S., "A new method for representing mixed-phase particle fall speeds in bulk microphysics parameterizations", J. Met. Soc. Japan, 86A(2008): 33-44.
- Efe, B.; Montes, S.; Unal, Y.; Tan, E.; Unal, E.; Ozdemir, T; et al., "72 hr forecast of wind power in Manisa, Turkey by using the WRF model coupled to WindSim", In Proceedings of the International conference on renewable energy research and applications (ICRERA 2012): 1-6.
- El-Fouly, T. H. M.; El-Saadany, E. F. and Salama, M. M. A., "Grey predictor for wind energy conversion systems output power prediction", IEEE Transactions on Power Systems, 21.3(2006): 1450-1452.
- Farrance, I. and Robert F., "Uncertainty in measurement: a review of Monte Carlo simulation using Microsoft Excel for the calculation of uncertainties through functional relationships, including uncertainties in empirically derived constants", The Clinical Biochemist Reviews 35.1 (2014): 37.
- Focken, U.; Lange, M. and Waldl, H. P., "Previento-a wind power prediction system with an innovative upscaling algorithm", In Proceedings of the European Wind Energy Conference, Copenhagen, Denmark (Vol. 276), (2001, June).
- Foley, M. A.; Leahy P. G.; Marvuglia, A. and McKeogh, E. J. "Current methods and advances in forecasting of wind power generation", Renewable Energy 37(2012) 1-8.
- Gaertner, M.A.; Gallardo, C.; Tejeda, C.; Martinez, N.; Calabria, S. and Fernandez, B., "The Casandra project: results of wind power 72-hr range daily operational forecasting in Spain," in Proceedings of the European Wind

- Energy Conference EWEC 2003, Madrid, Spain, July 16–19,2003.
- Giebel, G.; Brownsword, R.; Kariniotakis, G.; Denhard, M. and Draxl, C. “The State-Of-The-Art in Short-Term Prediction of Wind Power: A Literature Overview”, Risø National Laboratory Publication(2003).
- Giebel, G.; Landberg, L.; Nielsen, T. S. and Madsen, H., “The Zephyr Project–The Next Generation Prediction System”, In Proceedings of the 2001 European Wind Energy Conference, EWEC(Vol.1, 2002, April, pp.777-780).
- Giovannini, L.; Antonacci, G.; Zardi, D.; Laiti, L. and Panziera, L., “Sensitivity of simulated wind speed to spatial resolution over complex terrain”, Energy Procedia 59 (2014): 323-329.
- Gow, G., “Forecasting Short Term Wind Farm Production”, DTI contract no. W/45/00572 (2003).
- Grell, G. A. and Dévényi, D., “A generalized approach to parameterizing convection combining ensemble and data assimilation techniques”, Geophysical Research Letters 29.14 (2002): 38-1.
- Hayes, B. P.; Ilie, I.; Porpodas, A.; Djokic, S. Z. and Chicco, G., “Equivalent power curve model of a wind farm based on field measurement data”, 2011 IEEE Trondheim PowerTech. IEEE, 2011.
- Her, S.; Huh, J. and Kim, B., “Formula for estimating the uncertainty of manufacturer’s power curve in pitch-controlled wind turbines”, IET Renewable Power Generation 12.3 (2017): 292-297.
- Her, S.; Kim, B. S. and Huh, J. C., “Verification of the Validity of WRF Model for Wind Resource Assessment in Wind Farm Pre-feasibility Studies”, Transactions of the Korean Society of Mechanical Engineers B, 39.9(2015): 735-742.
- Holmberg, L. S., “Wind Power Forecasting. A wind turbine manufacturers perspective”, Wind Power Poland, PWEA 2016, Warsaw, Poland.
- Hong, S.-Y.; Dudhia, J. and Chen, S.-H., “A Revised Approach to Ice Microphysical Processes for th Bulk Parameterization of Clouds and Precipitation”,

- American Meteorological Society, 132.1(2004): 103-120.
- Hong, S.-Y.; Noh, Y. and Dudhia, J., "A new vertical diffusion package with an explicit treatment of entrainment processes", American Meteorological Society, 134.9(2006): 2318-2341.
- Hong, S.-Y., and Pan, H.-L., "Nonlocal boundary layer vertical diffusion in a Medium-Range Forecast model", Mon. Wea. Rev., 124(1996), 2322-2339.
- Hwang, M. Y.; Kim, S. H.; Yun, U. I.; Kim, K. D. and Ryu, K. H., "Building of Prediction Model of Wind Power Generation using Power Ramp Rate", Journal of the Korea Society of Computer and Information 17.1 (2012): 211-218.
- Jung, J. and Broadwater R. P. "Current status and future advances for wind speed and power forecasting", Renewable and Sustainable Energy Reviews 31(2014): 762-777.
- Jung, S.; Vanli O. A. and Kwon, S.-D., "Wind energy potential assessment considering the uncertainties due to limited data", Appl. Energy, 102(2013): 1492-1503.
- Kain, J. S., "The Kain-Fritsch convective parameterization: an update", Journal of applied meteorology 43.1 (2004): 170-181.
- Kariniotakis, G.; Mayer, D.; Halliday, J. A.; Dutton, A. G.; Irving, A. D.; Brownsword, R. A. and Alexiadis, M. C., "Load, wind and hydro power forecasting functions of the More-Care EMS system", Proc. Med Power 2002.
- Kavasseri, R. G. and Seetharaman, K., "Day-ahead wind speed forecasting using f-ARIMA models", Renewable Energy 34(2009): 1388-1393.
- Kelly, R., "New modeling techniques: From wind assessment and forecasting to wind resource management", presentation in the Bonneville Power Administration & California ISO's International Wind Forecast Techniques and Methodologies Workshop, Portland, Oregon. 2008.
- Kim, K. B.; Park, Y. H.; Park, J. K.; Ko, K. N. and Huh, J. C., "Feasibility study on wind power forecasting using MOS forecasting result of KMA", Journal of

- the Korean Solar Energy Society 30.2 (2010): 46-53.
- Kim, D. and Hur, J. "Short-term probabilistic forecasting of wind energy resources using the enhanced ensemble method", Energy 157(2018): 211-226.
- Kim, H. G.; Lee, Y. S.; Jang, M. S. and Kyong, N. H., "Development of the Wind Power Forecasting System, KIER Forecaster", Journal of the Korean society for New and Renewable Energy, 2.2(2006): 37-43.
- Kim, H. G.; Lee, Y. S.; Jang, M. S., "Cluster analysis and meteor-statistical model test to develop a daily forecasting model for Jeju wind power generation." Journal of Environmental Science International 19.10 (2010): 1229-1235.
- Kim, J. Y.; Kim, H. G.; Kang, Y. H.; Yun, C. Y.; Kim, J. Y.; and Lee, J. S., "A Simple Ensemble Prediction System for Wind Power Forecasting-Evaluation by Typhoon Bolaven Case", Journal of the Korean Solar Energy Society, 36.1(2016): 27-37.
- Kim, K.-H. and Hyun, S.-G., "Power Performance Testing and Uncertainty Analysis for a 3MW Wind Turbine", Journal of the Korean Solar Energy Society 30.6 (2010): 10-15.
- Kim, S.; Kim, J.; Ryn, K. R., "Learning Wind Speed Forecast Model for Predicting Power Generation by Wind Turbine", In Proceedings of KIIS Fall Conference 2014, Vol. 24, No. 2.
- Kusiak, A.; Zheng, H. and Song, Z., "Wind farm power prediction: a data-mining approach", WindEnergy: An International Journal for Progress and Applications in Wind Power Conversion Technology,12.3(2009):275-293.
- Kwon, S.-D., "Uncertainty analysis of wind energy potential assessment", Appl. Energy, 87.3(2010): 856-865.
- Landberg, L. "Short-term prediction of local wind conditions", Journal of Wind Engineering and Industrial Aerodynamics 89(2001): 235-245.
- Lang, S.; Mohrlen, C.; Jorgensen, J.; Gallachóir, B. O. and McKeogh, E., "Aggregate forecasting of wind generation on the irish grid using a multi-scheme

- ensemble prediction system”, In international solar energy society uk section-conference-c (Vol. 85, 2006, April, p. 89).
- Lange, M. and Focken, U. “State-of-the-art in wind power prediction in germany and international developments”, In Second Workshop of International Feed-In Cooperation (Vol. 94, 2005, December).
- Larson, K., “State-of-the art in wind forecasting”, presentation at Putting Wind on the Wires–ArizonaWindPowerForumFriday,Phoenix,Arizona.2008.
- Lin, Y.-L.; Farley, R. D. and Orville, H. D., “Bulk parameterization of the snow field in a cloud model”, J. Climate Appl. Meteor., 22(1983): 1065–1092.
- Lo, J. C. F.; Yang, Z. L. and Pielke, R. A., “Assessment of three dynamical climate downscaling methods using the Weather Research and Forecasting (WRF) model”, Journal of Geophysical Research: Atmospheres, 113.D9(2008).
- Mahmoud, G. M. and Hegazy, R. S., “Comparison of GUM and Monte Carlo methods for the uncertainty estimation in hardness measurements”, International Journal of Metrology and Quality Engineering 8 (2017): 14.
- Mao, Y. and Shaoshuai, W., “A review of wind power forecasting & prediction. In Probabilistic Methods Applied to Power Systems (PMAPS)”, 2016 International Conference, IEEE, (2016, October): 1-7.
- Maqsood, I.; Khan, M. R.; Huang, G. H. and Abdalls, R., “Application of soft computing models hourly weather analysis in southern Saskatchewan, Canada”, Engineering Applications of Artificial Intelligence 18 (2005): 115–125.
- Marti, I., “Wind Forecasting Activities,” in Proceedings of the First IEA Joint Action Symposium on Wind Forecasting Techniques, published by FOI Swedish Defence Research Agency, Norrköping, Sweden, pp. 11–20, Dec.2002.
- Mendoza, I.; Hur, J.; Thao, S. and Curtis, A., “Power performance test report for the US department of energy 1.5-Megawatt wind turbine”, NREL, Golden, Colo (2015): 1-55.
- Methaprayoon, K.; Yingvivanapong, C.; Lee, W. J. and Liao, J. R., “An integration

- of ANN wind power estimation into unit commitment considering the forecasting uncertainty”, IEEE Transactions on Industry Applications, 43.6(2007): 1441-1448.
- Mortensen, N.G.; Landberg, L.; Troen, I. and Petersen, E.L., “Wind Atlas Analysis and Application program (WAsP), Users Guide,” Risø National Laboratory, Roskilde, Denmark, 1993.
- Nielsen, H.Aa.; Nielsen, T.S.; Joensen, A.K.; Madsen, H.; and Holst, J., “Tracking timevarying coefficient-functions,” Int. J. of Adapt. Control and Signal Processing, vol. 14, no. 8, pp. 813–828,2000.
- Niu, G.-Y.; Yang, Z.-L.; Mitchell, K. E.; Chen, F.; Ek, M. B.; Barlage, M.; Kumar, A.; Manning, K.; Niyogi, D.; Rosero, E.; Tewari, M. and Xia, Y., “The community Noah land surface model with multiparameterization options (Noah-MP):1.Model description and evaluation with local-scale measurements”, Journal of Geophysical Research: Atmospheres 116.D12(2011).
- Okumus, I. and Dinler, A.“Current status of wind energy forecasting and a hybrid method for hourly predictions”, Energy Conversion and Management 123(2016): 362-371.
- Park, B. and Hur, J., “Accurate Short-Term Power Forecasting of Wind Turbines: The Case of Jeju Island’s Wind Farm”, Energies, 10.6(2017): 812.
- Park, Y. H.; Kim, K. B.; Her, S. Y.; Lee, Y. M. and Huh, J. C., “A study on the wind data analysis and wind speed forecasting in Jeju area”, Journal of the Korean Solar Energy Society 30.6 (2010): 66-72.
- Pei, L.; Moore, N.; Zhong, S.; Luo, L.; Hyndman, D. W.; Heilman, W. E. and Gao, Z., “WRF model sensitivity to land surface model and cumulus parameterization under short-term climate extremes over the southern Great Plains of the United States”, Journal of Climate 27.20 (2014): 7703-7724.
- Pinson, P., Kariniotakis, G., “On-line assessment of prediction risk for wind power

- production forecasts”, *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology* 7.2(2004):119-132.
- Pinson, P.; Madsen, H.; Nielsen, H. A.; Papaefthymiou, G., and Klöckl, B., “From probabilistic forecasts to statistical scenarios of short-term wind power production”, *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology* 12.1(2009):51-62.
- Precision Wind, *Precise Stream—Inside the Precision Wind Forecast Service*, brochure available at the Wind Power 2009 Exhibition, 2009.
- Quan, H., Dipti S. and Abbas K., “Short-term load and wind power forecasting using neural network-based prediction intervals”, *IEEE transactions on neural networks and learning systems* 25.2 (2014): 303-315.
- Rodrigues, A.; Peças Lopes, J.A.; Miranda, P.; Palma, L.; Monteiro, C.; Bessa, R.; Sousa, J.; Rodrigues, C. and Matos, J., “EPREV –A Wind Power Forecasting Tool for Portugal”, In *Proceedings of the European Wind Energy Conference EWEC2007, Milan, Italy, 2007*.
- Ruiz, J. J.; Saulo, C. and Nogués-Paegle, J., “WRF model sensitivity to choice of parameterization over South America: validation against surface variables”, *Monthly weather review* 138.8 (2010): 3342-3355.
- Salcedo-Sanc, S.; Perez-Bellido, AM.; Ortiz-Garcia, EG; Portilla-Figueras, A.; Priet, L.; Paredes, D., “Hybridizing the fifth generation mesoscale model with artificial neural networks for short-term wind speed prediction”, *Renew Energy* 34(2009): 1451-7
- Sanchez, I.; Usaola, J.; Ravelo, O.; Velasco, C.; Domínguez, J.; Lobo, M. G. and Alonso, M. “Sipreólico-a wind power prediction system based on flexible combination of dynamic models. application to the spanish power system” In *Poster on the World Wind Energy Conference in Berlin, Germany, (2002, June)*.
- Soman, S., S.; Zareipour, H.; Malik, O. and Mandal, P., “A review of wind power and wind speed forecasting methods with different time horizons”, *North*

- American power symposium (NAPS), 2010. IEEE, 2010.
- Stefanakos, Ch.N. and Vanem, E., "Nonstationary fuzzy forecasting of wind and wave climate in very long-term scales", *Journal of Ocean Engineering and Science* 3(2018): 144-155.
- Tascikaraoglu, A. and Uzunolu, M. "A review of combined approaches for prediction of short-term wind speed and power", *Renewable and Sustainable Energy Reviews* 34(2014):243-254.
- Taslimi-Renani, E.; Modiri-Delshad, M.; Elias, M. F. M. and Rahim, N. A., "Development of an enhanced parametric model for wind turbine power curve", *Applied energy* 177 (2016): 544-552.
- Teoen, I., and Mahrt, L., "A simple model of the atmospheric boundary layer sensitivity to surface evaporation", *Bound.-Layer Meteor.*, 37(1986), 129-148.
- Troen, I. and Petersen, E.L., "European Wind Atlas," published for the EU Commission DGXII by Risø National Laboratory, Denmark, 1998.
- Wang, J.; Botterud, A.; Bessa, R.; Keko, H.; Carvalho, L.; Issicaba, D.; Sumaili, J. and Miranda, V., "Wind power forecasting uncertainty and unit commitment", *Applied Energy* 88.11 (2011): 4014-4023.
- Yan, J.; Liu, Y.; Han, S.; Wang, Y. and Feng, S., "Reviews on uncertainty analysis of wind power forecasting", *Renewable and Sustainable Energy Reviews* 52 (2015): 1322-1330.
- Yang, H.; Qiu, J.; Meng, K.; Zhao, J. H.; Dong, Z. Y. and Lai, M., "Insurance strategy for mitigating power system operational risk introduced by wind power forecasting uncertainty", *Renewable Energy* 89 (2016): 606-615.
- Zack, J. W.; Brower, M. C. and Bailey, B. H., "Validating of the Forewind model in wind forecasting applications", In *Talk on the EUWEC Special Topic Conference Wind Power for the 21st Century*, Kassel, Germany (2000, September, pp. 25-27).
- Zuluaga, C. D., Alvarez, M. A. and Giraldo, E., "Short-term wind speed prediction

based on robust Kalman filtering: An experimental comparison”, Applied Energy 156(2015): 321-330.

Appendix

Appendix A. WRF model installation

□ 준비사항

- compiler (Intel, PGI, GNU)
- WRF source(Version 3.8.1) & WPS source(Version 3.8.1) 다운
url : http://www2.mmm.ucar.edu/wrf/users/download/get_source.html
- "read_wrf_nc" 코드 다운
url : http://www2.mmm.ucar.edu/wrf/users/download/get_source.html
- zlib(version 1.2.3), PNG(version 1.2.12), JasPer(1.701.0) source 다운
url : http://www2.mmm.ucar.edu/wrf/users/download/get_source.html
- Geographical Input Data 다운
url : http://www2.mmm.ucar.edu/wrf/users/download/get_sources_wps_geog.html
- Netcdf(version 4.1.3) 다운
url : <ftp://ftp.unidata.ucar.edu/pub/netcdf/netcdf-4.1.3.tar.gz>

□ 설치 순서

1. compiler 설치 -> 2. zlib 설치 -> 3. PNG 설치 -> 4. JasPer 설치 -> 5. Netcdf 설치
- > 6. WRF 설치 -> 7. WPS 설치

□ compiler 설치 방법

- 선택한 제품 매뉴얼 참조

□ zlib 설치

```
#!/bin/bash
export CC=icc
export CXX=icpc
export F77=ifort
```

```
export FC=ifort
export F90=ifort
export CPP='icpc =E'
export CXXCPP='icpc -E'
export FFLAGS='-O3 -xHost -ip -no-prec-div'
export CFLAGS='-O3 -xHost -ip -no-prec-div'
export CFFLAGS='-O3 -xHost -ip -no-prec-div'
./configure --prefix="설치경로"
make; make install
```

설치 성공 : libz.a 생성

□ PNG 설치

```
#!/bin/bash
export CC=icc
export CXX=icpc
export F77=ifort
export CPP='icpc =E'
export CXXCPP='icpc -E'
export FFLAGS='-O3 -xHost -ip -no-prec-div'
export CFLAGS='-O3 -xHost -ip -no-prec-div'
export CFFLAGS='-O3 -xHost -ip -no-prec-div'
./configure --prefix="설치경로"
make; make install
```

설치 성공 : libpng.a 생성

□ JasPer 설치

```
#!/bin/bash
export CC=icc
export CXX=icpc
export F77=ifort
```

```

export FC=ifort
export F90=ifort
export CPP='icpc -E'
export CXXCPP='icpc -E'
export FFLAGS='-O3 -xHost -ip -no-prec-div'
export CFLAGS='-O3 -xHost -ip -no-prec-div'
export CFFLAGS='-O3 -xHost -ip -no-prec-div'
export LDFLAGS='-L"/zlib, PNG 설치 경로" -lz -lpng'
    ex) '-L/path -lz -lpng'

```

./configure --prefix="설치경로"

make; make install

설치 성공 : libjasper.a 생성

□ Netcdf 설치

```

#!/bin/bash
export CC=icc
export CXX=icpc
export F77=ifort
export FC=ifort
export F90=ifort
export CPP='icpc -E'
export CXXCPP='icpc -E'
export FFLAGS='-O3 -xHost -ip -no-prec-div'
export CFLAGS='-O3 -xHost -ip -no-prec-div'
export CFFLAGS='-O3 -xHost -ip -no-prec-div'
export CPPFLAGS='-I"/zlib, PNG, JasPer 설치된 include 경로"'
    ex) '-I/path/include'
export LDFLAGS='-L"/zlib, PNG, JasPer 설치 lib 경로"'
    ex) '-L/path/lib'

```

./configure --prefix="설치경로"

make; make install

설치 성공 : libnetcdf.a, libnetcdf.a, netcdf.inc 생성

□ WRF 설치

○ 환경설정

- export NETCDF=/path
- export WRFIO_NCD_LARGE_FILE_SUPPORT=1
- JASPERINC=/path/include
- JASPERLIB=/path/lib
- source /opt/intel/compilers_and_libraries_2018/linux/bin/compilervars.sh intel64
- source /opt/intel/impi/2018.1.163/bin64/mpivars.sh intel64

○ 설 치

- ./configure 실행
- 해당되는 compiler와 병렬처리 방법의 옵션을 선택

```
checking for perl5... no
checking for perl... found /usr/bin/perl (perl)
Will use NETCDF in dir: /share_home/jmandel/lib/netcdf
PHDF5 not set in environment. Will configure WRF for use without.
```

```
If you REALLY want Grib2 output from WRF, modify the arch/Config_new.pl script.
Right now you are not getting the Jasper lib, from the environment, compiled into WRF.
```

```
-----
Please select from among the following supported platforms.
```

1. Linux x86_64, PGI compiler with pgcc (serial)
2. Linux x86_64, PGI compiler with pgcc (smpar)
3. Linux x86_64, PGI compiler with pgcc (dmpar)
4. Linux x86_64, PGI compiler with pgcc (dm+sm)
5. Linux x86_64 i486 i586 i686, ifort compiler with icc (serial)
6. Linux x86_64 i486 i586 i686, ifort compiler with icc (smpar)
7. Linux x86_64 i486 i586 i686, ifort compiler with icc (dmpar)
8. Linux x86_64 i486 i586 i686, ifort compiler with icc (dm+sm)
9. x86_64 Linux, gfortran compiler with gcc (serial)
10. x86_64 Linux, gfortran compiler with gcc (smpar)
11. x86_64 Linux, gfortran compiler with gcc (dmpar)
12. x86_64 Linux, gfortran compiler with gcc (dm+sm)

```
Enter selection [1-12] :
```

- "configure.wrf" 파일 수정 ※해당되는 상황에 맞게 수정
- ex) intel compiler인 경우 아래와 같이 변경

```

DM_CF = mpiifort -f90=$(SFC)
DM_CC = mpiicc -cc=$(SCC) -EMPI2_SUPPORT
CFLAGS_LOCAL = -w -O3 -ip -xHost
LDFLAGS_LOCAL = -ip -xHost
FCBASEOPTS_NO_G = -xHost ..... * "-xHost" 추가
LIB_EXTERNAL = -L$(WRF_SRC_ROOT_DIR)/external/io_netcdf -lwrpio_nf -
L/usr/local/lib -lnetcdf -lnetcdf
    * "-lz -lm"가 필요할 때도 있음

```

- ./compile em_real 2>&1 compile.log 실행
- 설치 성공 : run 폴더에 real.exe, wrf.exe, ndown.exe, tc.exe 생성
- 실패 시 : 설치로그파일을 살펴봐서 Error 메시지 확인 후 ./clean 실행하여 오브젝트 파일들을 삭제한 후 설치 재시도

□ WPS 설치

○ 환경설정

- WRF 환경설정과 동일

○ 설 치

- ./configure 실행
- 해당되는 옵션을 선택

```

Will use NETCDF in dir: /share_home/jmandel/lib/netcdf
Configuring to use jasper library to build Grib2 I/O...
$JASPERLIB = /share_home/jmandel/lib/netcdf/lib
$JASPERINC = /share_home/jmandel/lib/netcdf/include
$GEOTIFF or $LIBTIFF not found in environment, configuring to build without GeotIFF I/O...
-----
Please select from among the following supported platforms.

1. PC Linux x86_64, Intel compiler serial, NO GRIB2
2. PC Linux x86_64, Intel compiler serial
3. PC Linux x86_64, Intel compiler DM parallel, NO GRIB2
4. PC Linux x86_64, Intel compiler DM parallel
5. PC Linux i486 i586 i686,x86_64 gfortran compiler, serial, NO GRIB2
6. (gross) PC Linux x86_64, gfortran compiler, serial
7. PC Linux x86_64 (IA64 and Opteron), PGI compiler 5.2 or higher, serial, NO GRIB2
8. PC Linux x86_64 (IA64 and Opteron), PGI compiler 5.2 or higher, serial
9. PC Linux x86_64 (IA64 and Opteron), PGI compiler 5.2 or higher, DM parallel, NO GRIB2
10. PC Linux x86_64 (IA64 and Opteron), PGI compiler 5.2 or higher, DM parallel
11. PC Linux x86_64, g95 compiler, serial, NO GRIB2
12. PC Linux x86_64, g95 compiler, serial
13. PC Linux x86_64, g95 compiler, DM PARALLEL, NO GRIB2
14. PC Linux x86_64, g95 compiler, DM PARALLEL

Enter selection [1-14] :

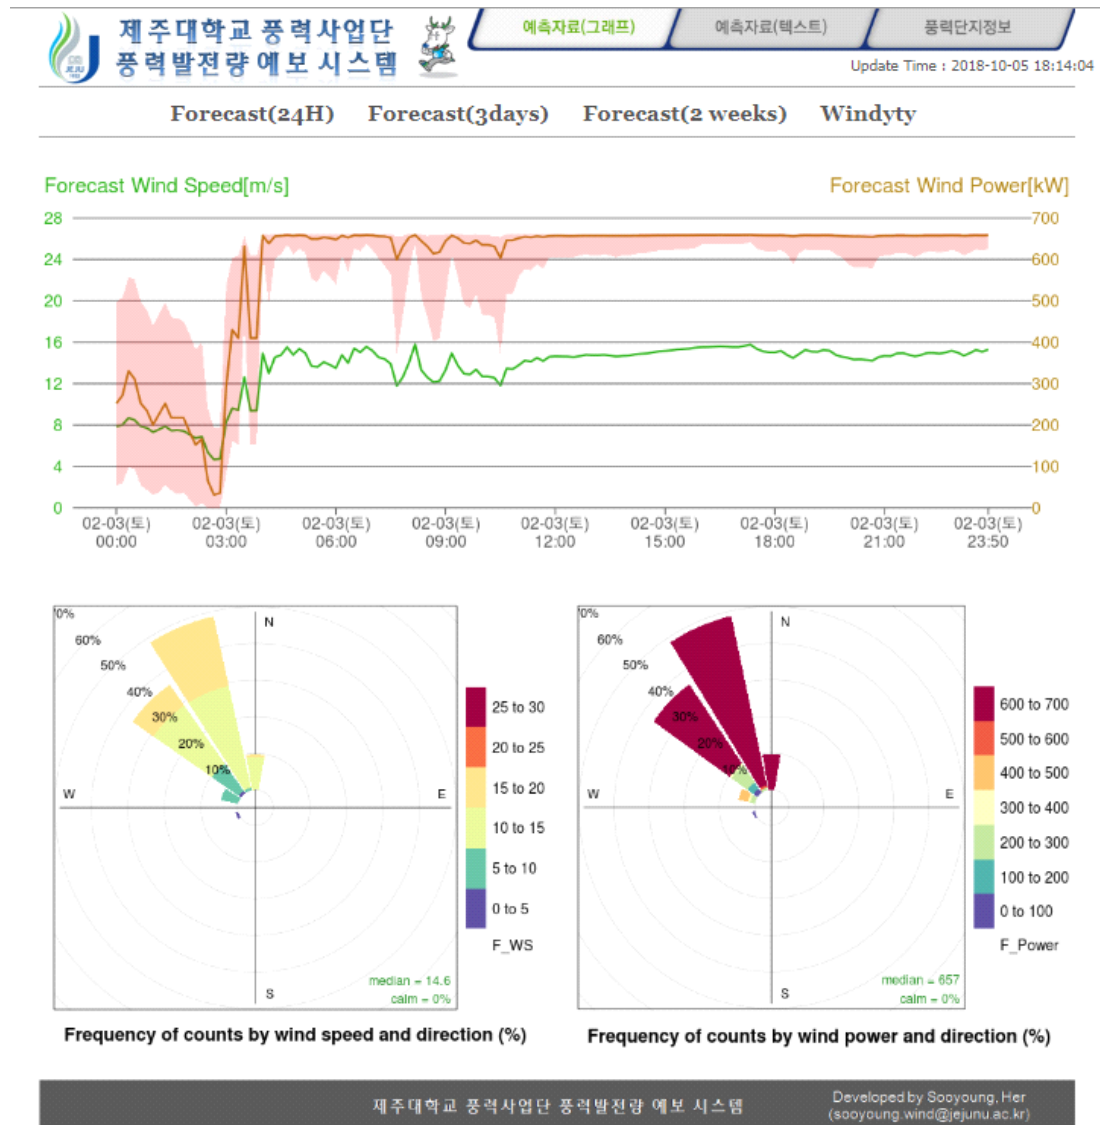
```

- “configure.wps” 수정
- 아래와 같이 “-lnetcdf” 추가하기

```
WRF_LIB = -L$(WRF_DIR)/external/io_grib1 -lio_grib1 \  
          -L$(WRF_DIR)/external/io_grib_share -lio_grib_share \  
          -L$(WRF_DIR)/external/io_int -lwr fio_int \  
          -L$(WRF_DIR)/external/io_netcdf -lwr fio_nf \  
          -L$(NETCDF)/lib -lnetcdf -lnetcdf
```



- ./compile em_real 2>&1 compile.log 실행
- 설치 성공 : geogrid.exe, ungrib.exe, metgrid.exe 생성
- 실패 시 : 설치로그파일을 살펴봐서 Error 메시지 확인 후 ./clean 실행하여 오브젝트 파일들을 삭제한 후 설치 재시도

Appendix B. Homepage for real-time wind power forecasting




Forecast(24H) Forecast(3days) Forecast(2 weeks) Windyty


Hourly Forecast Wind Speed[m/s] for 3 days



Wind Rose (2018-02-02 ~ 2018-02-02)



Wind Rose (2018-02-03 ~ 2018-02-03)




Wind Rose (2018-02-04 ~ 2018-02-04)




Forecast(24H) Forecast(3days) Forecast(2 weeks) Windy

Forecast Daily Wind Power Production[kWh] For 2 weeks



Forecast Daily Wind Power Production[kWh] For 2 weeks



Appendix C. Shell script for WRF model

C.1 GFS file download function

```
gfs_file_get(){
    cd "$GFS_PATH"
    if [ ! -d "$SYEAR" ]; then
        mkdir "$SYEAR"
    fi
    cd "$SYEAR"
    if [ ! -d gfs."$START_DATE" ]; then
        mkdir gfs."$START_DATE"
    fi
    NEW_GFS_PATH="$GFS_PATH"/"$SYEAR"/gfs."$START_DATE"
### Download GFS DATA for anl
    cd "$NEW_GFS_PATH"
    GFS_file_anl_name=gfs.t"$SHOUR"z.pgrb2."$GFS_file_deg".anl
###Download GFS DATA each time
    let index=0
    while [ "$index" -le "$RUNNING_TIME" ]; do
        if [ "$index" -le 9 ]; then
            indexstr='00'$index"
        elif [ "$index" -le 99 ]; then
            indexstr='0'$index"
        else
            indexstr="$index"
        fi

        GFS_file_full_name=gfs.t"$SHOUR"z.pgrb2."$GFS_file_deg".f"$indexstr"
        if [ ! -f "$GFS_file_full_name" ]; then
ncftpget ftpprd.ncep.noaa.gov ./ /pub/data/nccf/com/gfs/prod/gfs."$START_DATE"/"$GFS_file_full_name"
            if [ "$?" -ne 0 ]; then
```

```

        echo rm -f "$GFS_file_full_name"
        rm -f "$GFS_file_full_name"
        return 1
    fi
else
    echo "$GFS_file_full_name" Exists
fi
let index=index+gfs_step_time
done
return 0
}

```

C.2 WPS Process function

```

wps_process()
{
    echo WPS RUN-----
    echo EDIT WPS namelist.wps-----
    rm -f namelist.wps
    cp -f $WPS_namelist namelist.wps.temp
        linecount=`wc -l namelist.wps.temp | cut -d' ' -f1`
        start_date_line=`grep start_date namelist.wps.temp -n | cut -d':' -f1`
        end_date_line=`grep end_date namelist.wps.temp -n | cut -d':' -f1`
        head -n $((start_date_line-1)) namelist.wps.temp > namelist.wps
    echo          '          start_date          =
""""$SYEAR"-"$SMONTH"-"$SDAY"_"$SHOUR":00:00"""" , """"$SYEAR"-"$SMONTH"-"$SDAY"_"$
SHOUR":00:00"""" , """"$SYEAR"-"$SMONTH"-"$SDAY"_"$SHOUR":00:00"""" , """"$SYEAR"-"$SMO
NTH"-"$SDAY"_"$SHOUR":00:00"""" , """"$SYEAR"-"$SMONTH"-"$SDAY"_"$SHOUR":00:00"""" ,
""""$SYEAR"-"$SMONTH"-"$SDAY"_"$SHOUR":00:00"""" , ' >> namelist.wps
    echo          '          end_date          =
""""$EYEAR"-"$EMONTH"-"$EDAY"_"$EHOUR":00:00"""" , """"$SYEAR"-"$SMONTH"-"$SDAY"_"$
SHOUR":00:00"""" , """"$SYEAR"-"$SMONTH"-"$SDAY"_"$SHOUR":00:00"""" , """"$SYEAR"-"$SMO
NTH"-"$SDAY"_"$SHOUR":00:00"""" , """"$SYEAR"-"$SMONTH"-"$SDAY"_"$SHOUR":00:00"""" ,

```



```
""""$SYEAR"-"$SMONTH"-"$SDAY"_"$SHOUR":00:00"""";' >> namelist.wps

    let tail_line=linecount-end_date_line

tail -n "$tail_line" namelist.wps.temp >> namelist.wps

rm -f namelist.wps.temp

echo namelist.wps-----
cat namelist.wps
echo -----
echo RUN geogrid.exe-----
time ./geogrid.exe
rsl_message=`grep Successful geogrid.log | wc -l`
if [ "$rsl_message" != "1" ]; then
    echo -----
    echo geogrid.exe NOT successful!!!
    echo -----
    break
fi

    echo LINK gfs-----
NEW_GFS_PATH="$GFS_PATH"/"$SYEAR"/gfs."$START_DATE"
./link_grib.csh "$NEW_GFS_PATH"/gfs.t"$SHOUR"z.pgrb2."$GFS_file_deg"*
echo ungrib.exe-----
time ./ungrib.exe
rsl_message=`grep Successful ungrib.log | wc -l`
if [ "$rsl_message" != "1" ]; then
    echo -----
    echo ungrib.exe NOT successful!!! for ERA_SC
    echo -----
    break
fi

echo metgrid.exe-----
time ./metgrid.exe
rsl_message=`grep Successful metgrid.log | wc -l`
```

```

if [ "$rsl_message" != "1" ]; then
    echo -----
    echo metgrid.exe NOT successful!!!
    echo -----
    break
fi
}

```

C.3 Edit namelist function

```

edit_namelist()
{
    echo EDIT WRF namelist.input-----
    linecount=`wc -l namelist.input.temp | cut -d' ' -f1`
    start_date_line=`grep start_year namelist.input.temp -n | cut -d':' -f1`
    end_date_line=`grep end_second namelist.input.temp -n | cut -d':' -f1`
    echo ' &time_control' > namelist.input
    echo ' run_days = 0,' >> namelist.input
    echo ' run_hours = "$RUNNING_TIME",' >>
namelist.input
    echo ' run_minutes = 0,' >> namelist.input
    echo ' run_seconds = 0,' >> namelist.input
    #Edit below lines for modify domain number.
    echo ' start_year = "$SYEAR",' "$SYEAR",' "$SYEAR",'
"$SYEAR",' "$SYEAR",' "$SYEAR",' >> namelist.input
    echo ' start_month = "$SMONTH",' "$SMONTH",'
"$SMONTH",' "$SMONTH",' "$SMONTH",' "$SMONTH",'>> namelist.input
    echo ' start_day = "$SDAY",' "$SDAY",' "$SDAY",'
"$SDAY",' "$SDAY",' "$SDAY",' >> namelist.input
    echo ' start_hour = "$SHOUR",' "$SHOUR",'
"$SHOUR",' "$SHOUR",' "$SHOUR",' "$SHOUR",' >> namelist.input
    echo ' start_minute = "00",' '00",' '00",' '00",' '00',' >>
namelist.input
}

```

```

        echo ' start_second                = "00",' '00',' '00',' '00',' '00',' '00','>>
namelist.input
        echo ' end_year                    = "$EYEAR",' "$EYEAR",'
"$EYEAR",' "$EYEAR",' "$EYEAR",' "$EYEAR",' >> namelist.input
        echo ' end_month                   = "$EMONTH",' "$EMONTH",'
"$EMONTH",' "$EMONTH",' "$EMONTH",' "$EMONTH",'>> namelist.input
        echo ' end_day                     = "$EDAY",' "$EDAY",' "$EDAY",'
"$EDAY",' "$EDAY",' "$EDAY",' >> namelist.input
        echo ' end_hour                    = "$EHOUR",' "$EHOUR",'
"$EHOUR",' "$EHOUR",' "$EHOUR",' "$EHOUR",' >> namelist.input
        echo ' end_minute                  = "00",' '00',' '00',' '00',' '00','
'00','>> namelist.input
        echo ' end_second                  = "00",' '00',' '00',' '00',' '00','
'00','>> namelist.input

        #Don't edit below lines.
        let tail_line=linecount-end_date_line
        tail -n "$tail_line" namelist.input.temp >> namelist.input
        rm -f namelist.input.temp
    }

```

C.4 WRF Process function(for parent domain)

```

wrf_parent()
{
    echo -----
    echo WRF
    echo -----
    cd "$WRF_parent"
    rm -f namelist.input
    cp -f $WRF_namelist_parent namelist.input.temp
        echo EDIT WRF namelist.input-----
    edit_namelist
    echo wrf_parent-----
}

```

```

cat namelist.input
echo -----
echo LINK met_em.d0*-----
ln -sf "$WPS_PATH"/met_em.d0*.nc .
echo real.exe-----
time ./real.exe
rsl_message=`grep SUCCESS rsl.error.0000 | wc -l`
if [ "$rsl_message" != "1" ]; then
    echo -----
    echo real.exe NOT successful!!! for wrf_parent
    echo -----
    break
fi
echo wrf.exe-----
echo START WRF : `date`
time mpiexec -n "$NTOTALCPU" ./wrf.exe
rsl_message=`grep SUCCESS rsl.error.0000 | wc -l`
if [ "$rsl_message" != "1" ]; then
    echo -----
    echo wrf.exe NOT successful!!! for wrf_parent
    echo -----
    break
fi
echo END WRF : `date`
}

```

C.5 WRF Process function(for nesting domain)

```

wrf_pbl()
{
    echo -----
    echo WRF
    echo -----
}

```

```
cd "$WRF_pbl"
rm -f namelist.input
cp -f $WRF_namelist_all namelist.input.temp
    echo EDIT WRF namelist.input-----
edit_namelist
echo LINK met_em.d0*-----
ln -sf "$WPS_PATH"/met_em.d0*.nc .
echo real.exe-----
time ./real.exe
rsl_message=`grep SUCCESS rsl.error.0000 | wc -l`
if [ "$rsl_message" != "1" ]; then
    echo -----
    echo real.exe NOT successful!!! for wrf_pbl
    echo -----
    break
fi
    echo ndown.exe-----
mv wrfinput_d02 wrfndi_d02
mv wrfinput_d03 wrfndi_d03
mv wrfinput_d04 wrfndi_d04
cp -f $WRF_namelist_ndown namelist.input.temp
edit_namelist
echo "START PBL(ndown.exe) : " `date`
ln -sf "$WRF_parent"/wrfout_d01_* .
time ./ndown.exe
rsl_message=`grep SUCCESS rsl.error.0000 | wc -l`
if [ "$rsl_message" != "1" ]; then
    echo -----
    echo ndown.exe NOT successful!!! for wrf_pbl
    echo -----
    break
```

```
fi
rm ./wrfout_d01_*
echo wrf.exe-----
cp -f $WRF_namelist_d03 namelist.input.temp
edit_namelist
echo wrf_parent-----
cat namelist.input
echo -----
mv wrfbdy_d02 wrfbdy_d01
mv wrfndi_d02 wrfinput_d01
mv wrfndi_d03 wrfinput_d02
mv wrfndi_d04 wrfinput_d03
echo START WRF : `date`
time mpiexec -n "$NTOTALCPU" ./wrf.exe
rsl_message=`grep SUCCESS rsl.error.0000 | wc -l`
if [ "$rsl_message" != "1" ]; then
    echo -----
    echo wrf.exe NOT successful!!! for wrf_pbl
    echo -----
    break
fi
echo END WRF : `date`
}
```