

해상상태를 고려한 CNN 기반의 부유형 풍력 터빈 회전 상태 구분

김응빈*, 최인식**

Rotation State Classification of Floating Wind Turbine based on CNN Considering Sea State

EungBeen Kim*, In-Sik Choi**

이 논문은 2021년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2021R111A3043120)

요 약

본 논문에서는 부유형 풍력 발전에서 해상상태에 따른 풍력 블레이드의 회전 상태를 구분하는 것에 대한 연구를 진행하였다. 이를 위해 전자파 수치해석 시뮬레이션, 실내 및 실외 측정을 수행하였다. 각 측정에서 구분에 필요한 데이터를 얻기 위하여 파고와 주기를 일반적으로 사용되고 있는 9단계의 해상상태가 아닌 총 4단계로 나누어 진행하였다. 훈련 데이터로는 노이즈가 없는 환경을 가정하여 잡음이 없는 스펙트로그램을 사용하였고, 테스트 데이터는 SNR이 5dB, 10dB, 15dB, 20dB에 해당하는 가우시안 노이즈를 추가하여 구분을 진행하였다. CNN(Convolutional Neural Network) 구분기를 이용한 실험 결과 SNR이 높아짐에 따라 구분 성능이 향상됨을 알 수 있고, 몬테카를로 시뮬레이션을 50회 진행하여 얻은 구분 정확도는 시뮬레이션, 실내 측정, 실외 측정 모두에서 92% 이상을 가짐을 확인하였다.

Abstract

This paper focuses on distinguishing the rotation states of wind turbine blades in floating wind system when sea states are considered. To implement our ideas, we conducted electromagnetic numerical simulation, indoor and outdoor measurements. The experiments categorize the sea states into four different levels instead of the conventional nine levels to distinguish clearly the wave height and period. The training data consists of noise-free spectrograms, while the test data is added with the Gaussian noise at the given signal-to-noise ratio(SNR) of 5 dB, 10dB, 15dB, and 20dB. The results using the Convolutional Neural Network(CNN) classifier indicate that the performance is improved as the SNR increases. 50 Monte Carlo simulations are conducted and the classification accuracy is higher than 92% at all cases of using the numerical simulation, indoor and outdoor measurement data.

Keywords

floating wind turbine, rotation state, sea state, Monte Carlo simulation, CNN classifier

* 한남대학교 전기전자공학과

- ORCID: <https://orcid.org/0000-0001-6636-5465>

** 한남대학교 전기전자공학과 교수(교신저자)

- ORCID: <https://orcid.org/0000-0002-8210-0843>

• Received: Feb. 04, 2024, Revised: Mar. 15, 2024, Accepted: Mar. 18, 2024

• Corresponding Author: In-Sik Choi

Dept. of Electrical and Electronic Engineering, Hannam University, 70

Hannam-ro, Daeduk-gu, Daejeon, 34430, Korea

Tel.: +82-42-629-8568, Email: recog@hnu.kr

I. 서 론

20세기부터 전 세계적으로 과학기술이 발달함에 따라 산업화와 도시화가 가속되었다. 이로 인해 다양한 화석연료의 소비가 급격히 이루어지며 지구환경 문제를 야기하였다[1]. 때문에 전 세계적으로 대체 가능한 에너지인 천연자원과 자연 친화적인 방법으로 에너지를 얻을 수 있는 태양열, 수력, 지열, 풍력 등 재생 가능한 에너지에 대한 기술적 수요 및 관심이 증가하고 있다. 이중 풍력 발전은 태백산맥과 소백산맥을 가지고 있는 산간지역과 발전하는데 충분한 풍속이 있는 우리나라에서 각광받는 에너지원이다[2]. 하지만 풍력 발전기의 경우 외부에 노출되어 있어 손상 및 고장에서 자유로울 수 없다. 손상의 원인으로는 지속적인 바람으로 인해 주기적으로 변하는 하중 피로에 의한 손상, 재료의 노화, 제조 결함, 유지 보수 문제, 기상 조건, 철새의 충돌 등 다양하다. 만일 풍력 블레이드의 손상이 발생될 경우 블레이드 각각의 질량 분포에 영향을 주기 때문에 불균형 회전이 이루어진다. 블레이드의 손상으로 인하여 불균형 회전이 유지될 경우 전력 생산과 초기 유지 보수에 대한 비용에 영향을 준다[3]. 때문에 조기에 블레이드의 회전상태를 구분할 수 있는 연구들이 관심을 받고 있다.

최근에 진행되고 있는 연구는 블레이드 내부 광섬유 센서를 삽입하는 방법[4]과 초음파 센서를 삽입하는 방법[5]이 있다. 또 카메라를 이용하여 영상을 획득하여 기계 학습을 통하여 분석하는 방법[2]과 움직임 벡터를 측정하는 방법[6]과 원격 제어 드론을 이용하여 유지 보수를 하는 방법이 있다[7]. 하지만 이러한 방법들은 초기 제작비용이 비싸고 광학 센서는 낮에만 탐지가 가능하기 때문에 이를 극복할 수 있는 방안으로 레이더를 이용하여 고장을 탐지하고 회전 상태를 구분하는 연구들이 활발하게 진행되고 있다.

레이더를 이용하여 회전 상태를 구분한 연구로서 육상풍력발전기의 파손 여부와 회전 상태를 구분하는 연구[8], 전자파 수치해석 시뮬레이션을 이용하여 코닝 모션 상태에서 회전 상태를 구분하는 연구[9], 전자파 수치 해석 시뮬레이션을 이용하여 코닝

모션 상태에서 가우시안 노이즈를 추가하였을 때의 회전 상태를 구분하는 연구[10], 해상상태를 고려한 전자파 수치해석 시뮬레이션에 대한 회전 상태 구분 연구[11] 등이 있다.

본 논문에서는 기존 선행연구[8]-[11]와 달리 해상상태별로 다양한 노이즈 환경에서 전자파 수치해석 시뮬레이션 및 실내외 측정 데이터에 대한 블레이드의 회전 상태를 구분하는 연구를 진행한다. 이러한 실험이 진행되기 앞서 각각의 해상 상태별 데이터들의 차이가 명확하도록 일반적으로 사용되고 있는 해상 상태 0~9단계[12]를 총 4단계로 간략화시켰다. 전체 실험 데이터는 먼저 전자파 수치해석 시뮬레이션으로 4단계 해상상태에 따른 스펙트로그램을 획득하였다. 다음으로 3D Motion Platform 및 풍력 스케일 모델을 제작하여 실내 측정 환경을 구성하였으며[13], 이를 24GHz 도플러 레이더를 이용하여 각 해상상태별 원시 데이터를 획득하였다. 마지막으로 직접 바다 및 강에 나가 실외 측정 환경을 구성하여 실내 측정과 마찬가지로 각 해상 상태별 원시 데이터를 획득하였다[14]. 구분 테스트를 위해 획득한 원시데이터에 SNR이 5dB, 10dB, 15dB, 20dB가 되도록 가우시안 노이즈를 추가하였다. 학습 데이터로는 노이즈가 없는 스펙트로그램, 테스트 데이터로는 가우시안 노이즈가 추가된 스펙트로그램 영상을 이용하였으며, CNN 구분기를 이용하여 구분한 최종 구분결과를 제시하였다.

II. 관련 이론

2.1 CNN

일반적으로 신경망은 입력 계층, 은닉 계층, 출력 계층으로 구성되어 있다. 이 중 다수의 은닉 계층으로 이루어져있는 경우 딥러닝(Deep learning)이라 부른다. 일반적으로 딥러닝은 입력 데이터를 1차원의 형태로 변환하는 작업을 진행하게 되는데 이때 데이터의 손실이 발생하게 된다. 또 모든 노드들이 서로 연결되어 있으며 각 노드들 간의 가중치를 학습하기 때문에 은닉계층이 많을수록 학습 시간이 길어진다.

따라서 다차원으로 이루어진 이미지를 구분하는 데에는 적합하지 않다. 이러한 한계를 극복하기 위하여 이미지를 구분하는데 사용되어지는 대표적인 알고리즘이 CNN이다. CNN은 노드 간의 사전의 고정된 연결 없이 컨볼루션 과정에서 학습을 진행하며, 필터의 가중치를 학습시켜 더 나은 방향으로 학습을 진행한다. 본 논문에서 사용한 CNN의 구조는 그림 1과 같다. 이미지가 입력되었을 때 특징을 추출하는 Feature extraction과 결과값을 도출하는 Classification 두 영역으로 구성되어 있다. Feature extraction 영역에서는 이미지 입력이 들어오게 되었을 때, 그림 2와 같이 필터를 통하여 특성맵(Feature map)을 추출하고, 풀링(Pooling)의 과정을 통하여 특성맵의 차원을 줄이는 과정을 수행한다.

특성 맵을 추출하기 위해선 영상의 각 픽셀의 해당하는 값에 특징을 추출하기 위한 필터 혹은 커널이라고 불리는 네모 상자가 영상의 왼쪽 최상단에서부터 오른쪽 최하단으로 이동하는 스트라이드(Stride) 기법을 이용한다. 스트라이드 기법을 통하여 추출된 특성 맵은 입력 영상과 필터의 컨볼루션 연산 수행 과정에서 본래의 입력 영상의 행렬보다

작은 행렬을 추출하기 때문에 정보의 손실이 발생된다. 이를 방지하고자 입력 영상의 테두리를 '0'으로 감싸는 제로패딩(Zero padding)방식을 사용한다. 제로패딩은 입력 영상의 행렬 크기를 확장함으로써 스트라이드 기법을 적용했을 때 크기를 동일하게 유지하여 정보의 손실을 방지할 수 있다. 제로패딩의 과정을 통하여 추출된 특성 맵의 높이와 폭은 식 (1)과 같은 방식으로 정의될 수 있다.

$$Feature\ map\ Height = \frac{IH+2P-FH}{S} + 1 \quad (1)$$

$$Feature\ map\ Width = \frac{IW+2P-FW}{S} + 1$$

여기서 IH(Input Height)와 IW(Input Width)는 입력 영상의 높이와 폭을, FH(Filter Height)와 FW(Filter Width)는 필터의 높이와 폭, P는 패딩 사이즈, S는 스트라이드의 크기를 나타낸다. Pooling 레이어는 Feature map 차원을 줄이기 위한 과정이며 클래스의 구분은 Fully connected layer와 Output layer에서 이루어진다.




그림 1. CNN 구조
Fig. 1. Structure of CNN




그림 2. 특성맵 추출 과정
Fig. 2. Extraction process of feature map

2.2 해상상태별 블레이드 상태 구분 실험

본 논문에서는 구분기의 성능 및 신뢰도를 확보하기 위하여 몬테 카를로 기법을 사용하였다. 몬테 카를로는 무작위 추출된 난수를 이용하여 신뢰성이 높은 결과값을 도출하기 위한 방법이다. 따라서 몬테카를로 시뮬레이션을 적용하기 위하여 학습시킬 데이터인 원시데이터(Raw data)에 가우시안 노이즈를 첨가하였다. 식 (2)는 각 SNR별 노이즈의 전력을 계산하는 방법이다.

$$\sigma^2 = P_{sig} 10^{-\frac{SNR}{10}} \quad (2)$$

σ^2 은 평균 잡음 전력을 나타내며 P_{sig} 는 원시 데이터의 평균 전력을 나타낸다.

그림 3은 본 논문에서 제안하는 블레이드 상태 구분 실험의 순서도를 보여준다. 이때 전체 데이터는 해상상태 1~4까지를 전부 합친 데이터를 의미하며, Training phase의 경우 전체 데이터의 70%를 훈련 데이터로 사용하였으며, 시간-주파수 분석 방법인 STFT(Short Time Fourier Transform) 기법을 이용하여 스펙트로그램을 획득하였다. 이렇게 획득한 스펙트로그램은 CNN구분기를 이용하여 훈련을 진행하였다. 또한 Test phase의 경우엔 전체 데이터의 30%를 테스트 데이터로 사용하였으며, SNR이 5, 10, 15, 20dB에 해당하는 노이즈를 추가하였다.

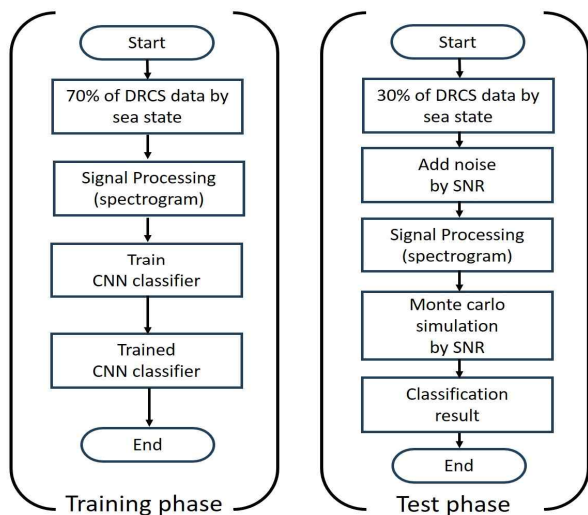



그림 3. 제안하는 블레이드 상태 구분 실험의 순서도
Fig. 3. Flowchart of proposed blade state classification process

이후 Training phase와 같은 방법인 STFT 기법을 이용하여 스펙트로그램을 획득하였으며, 신뢰도를 높이기 위해 SNR별로 몬테 카를로 시뮬레이션 50회를 진행하여 평균값을 도출하였다.

III. 실험 결과

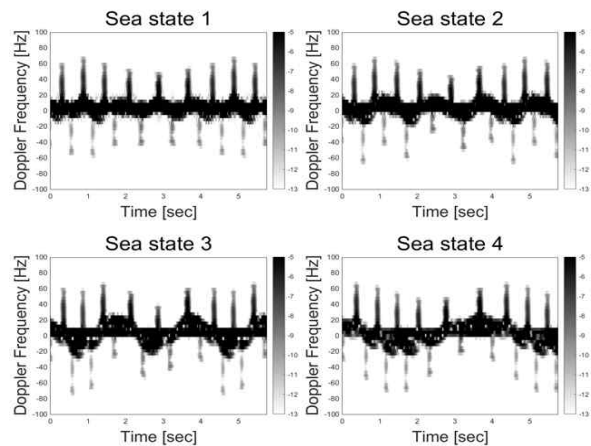
3.1 데이터 획득

본 논문에서는 여러 해상상태별 데이터로부터 정상 회전과 불균형 회전 상태를 구분하는 것을 목표로 한다. 수치해석 시뮬레이션[15]을 통해 얻은 스펙트로그램 영상은 그림 4와 같다. 그림 4를 보게 되면 해상상태가 증가할수록 도플러 주파수 변화가 심하며, 주기도 증가함을 볼 수 있다.



(a) 정상회전

(a) Normal rotation



(b) 불균형회전

(b) Imbalance rotation

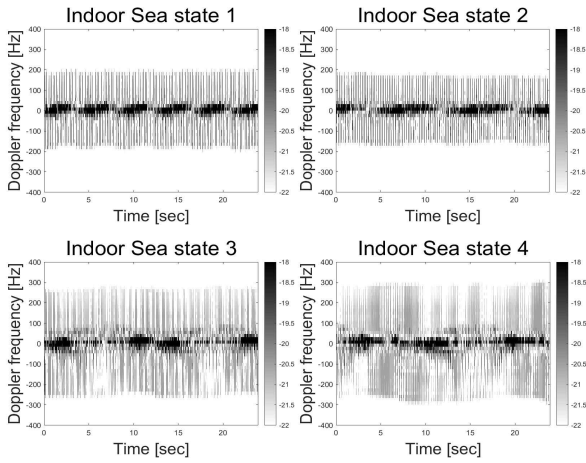
그림 4. 해상상태별 스펙트로그램(시뮬레이션)

Fig. 4. Spectrogram by sea state(simulation)

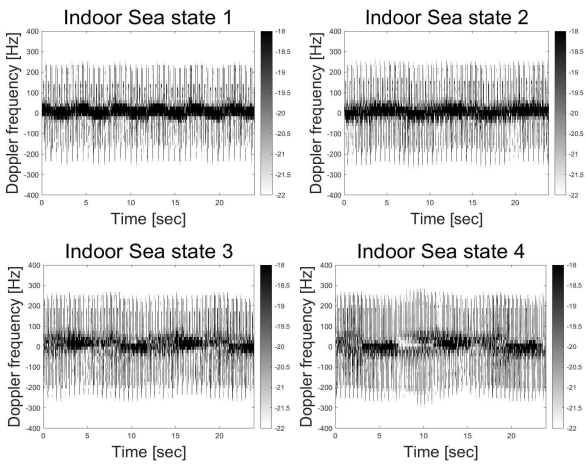
그림 5는 24초간 실내 측정을 통해 얻은 스펙트로그램이다. 그림 4와 같이 해상 상태가 증가할수록 도플러 주파수 변화가 심하며, 주기도 증가함을 볼 수 있다. 또한 식 (3)의 도플러 주파수 식에 의하여 정상 회전 및 불균형 회전의 차이를 그림 5를 통하여 볼 수 있다.

$$f_d = -\frac{2\nu}{\lambda} \quad (3)$$

f_d 는 도플러 주파수, ν 는 속도, λ 는 파장을 의미한다.



(a) 정상회전
(a) Normal rotation

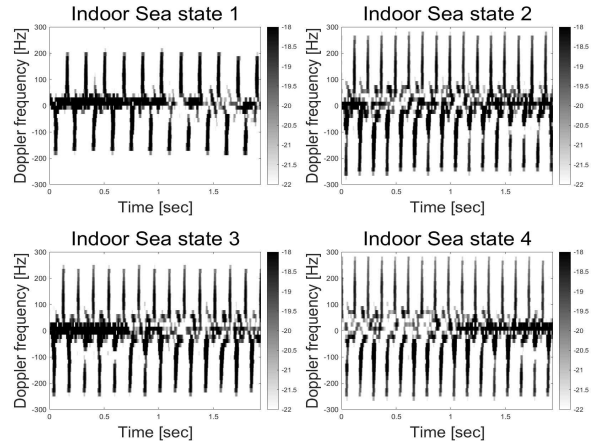


(b) 불균형회전
(b) Imbalance rotation

그림 5. 해상상태별 스펙트로그램(실내측정)
Fig. 5. Spectrogram by sea state(indoor measurement)

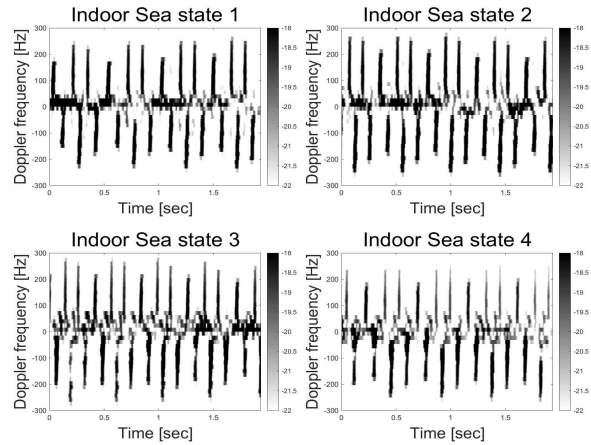
본 논문에서는 스펙트로그램의 차이를 더욱 명확히 확인하기 위하여 2초까지만 실내 측정을 다시

수행하였다. 그림 6과 그림 7은 2초 동안 관측한 실내 측정 및 실외 측정 스펙트로그램이다.



(a) 정상회전

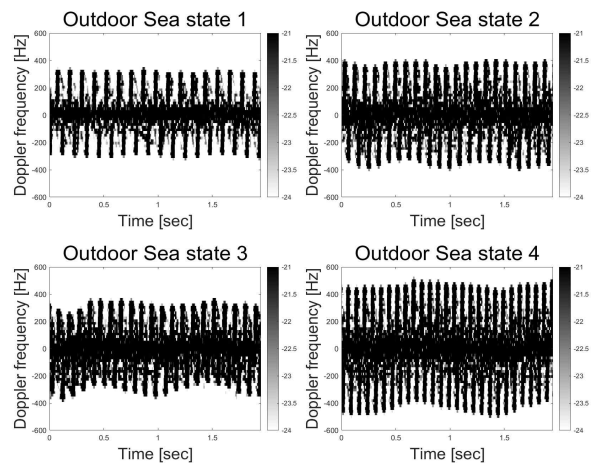
(a) Normal rotation



(b) 불균형회전

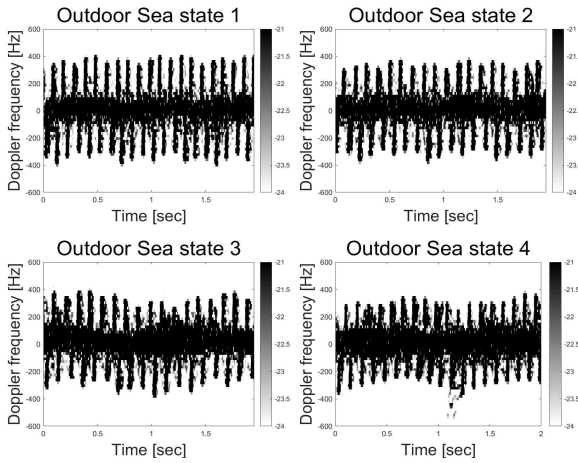
(b) Imbalance rotation

그림 6. 2초 관측시간에 대한 스펙트로그램(실내)
Fig. 6. Spectrogram for two second observation(Indoor)



(a) 정상회전

(a) Normal rotation



(b) 불균형회전
(b) Imbalance rotation

그림 7. 해상상태별 스펙트로그램(실외측정)
Fig. 7. Spectrogram by sea state(outdoor measurement)

그림 8은 정상회전 상태를 CNN으로 훈련 시키는 과정에서 convolution layer 1단계 특성맵의 예를 보여주고 있다.




그림 8. 정상 회전 상태의 특성맵
Fig. 8. Feature map of normal rotation

3.2 구분 결과

표 1, 2, 3은 시뮬레이션, 실내 측정, 실외 측정에 대하여 데이터를 획득한 파라미터를 보여주는 표이다. 야외 측정의 경우는 여건상 정확한 관측각도를 알수가 없어 표기하지 않았으며 관측각도를 바꾸면서 여러번 측정을 수행하였다.

표 1, 2, 3에서 알 수 있듯이 전체 데이터 중에서 훈련 데이터와 테스트 데이터는 7:3으로 나눈 후 구분 실험을 진행하였다.

표 1. 시뮬레이션 데이터 파라미터

Table 1. Specification of radar used for measurement

Parameter	Value
Azimuth angle	0° ~ 30° (0.5° step)
Sea state	1 ~ 4
SNR	10dB~20dB (5dB step)
# of Monte Carlo simulation	50
# of total spectrogram	1024
# of Train data	716
# of Test data	308

표 2. 실내 측정 데이터 파라미터

Table 2. Indoor measurement data parameters

Parameter	Value
Azimuth angle	0° ~ 30° (5° step)
Sea state	1 ~ 4
SNR	10dB~20dB (5dB step)
# of Monte Carlo simulation	50
# of total spectrogram	840
# of Train data	588
# of Test data	252

표 3. 실외 측정 데이터 파라미터

Table 3. Outdoor measurement data parameters

Parameter	Value
Sea state	1 ~ 4
SNR	10dB~20dB (5dB step)
Mesurement spot	Youngdeok and Kyeryong Mountain
# of Monte Carlo simulation	50
# of total spectrogram	100
# of Train data	70
# of Test data	30

표 4, 5, 6은 5 dB SNR에서 학습한 모델의 구분 성능을 보여주기 위하여 혼동 행렬(Confusion matrix)를 이용하여 나타낸 것이다. 불균형 회전이 균형 회전에 비해 플래시의 변화가 더 불규칙하기 때문에, 노이즈의 영향을 더 많이 받아 3가지 경우 모두에서 불균형 회전을 정상 회전 상태로 잘못 구분한 경우가 더 많았다.

표 4. 시뮬레이션 데이터에 대한 SNR=5dB에 혼동행렬
Table 4. Confused matrix for SNR=5dB for simulation data

	Predicted	Normal	Imbalance
Actual			
Normal		7313	387
Imbalance		523	7177

표 5. 실내 측정 데이터에 대한 SNR=5dB에 혼동행렬
Table 5. Confused matrix for SNR=5dB for indoor measurement data

	Predicted	Normal	Imbalance
Actual			
Normal		5893	407
Imbalance		513	5787

표 6. 실외 측정 데이터에 대한 SNR=5dB에 혼동행렬
Table 6. Confused matrix for SNR=5dB for outdoor measurement data

	Predicted	Normal	Imbalance
Actual			
Normal		699	51
Imbalance		68	682

표 7과 그림 9은 SNR에 따른 구분 결과를 표와 그래프로 나타내었다. 5 dB의 SNR에서 92% 이상의 구분 성능을 보였으며, 20 dB에서는 98% 이상의 구분 성능을 가짐을 알 수 있다. 또한 시뮬레이션 데이터가 가장 좋은 성능을 가졌으며, 야외에서 측정 한 데이터가 가장 나쁜 성능을 보였는데 이는 아무래도 측정에 대한 부정확성이 원인으로 보인다.

표 7. SNR별 구분 정확도
Table 7. Classification accuracy by SNR

	SNR	5dB	10dB	15dB	20dB
Method					
Simulation		95.4%	98.3%	100%	100%
Indoor measurement		92.7%	94.7%	97.8%	98.4%
Outdoor measurement		92.06%	93.4%	96.4%	98.1%

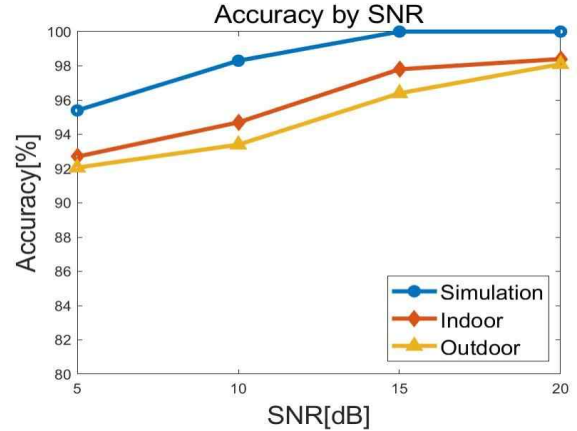


그림 9. SNR에 따른 정확도 그래프
Fig. 9. Graph for accuracy by SNR

본 논문에서 24GHz 도플러 레이더를 이용해 시뮬레이션, 실내 측정, 실외 측정을 수행하였고, 각각의 측정 데이터를 이용해 풍력 블레이드의 정상 회전과 불균형 회전을 구분하였다. 3가지 방법 모두 구분 성능에는 차이가 있었지만 풍력 터빈의 회전 상태 구분에는 문제가 없는 것을 확인하였다.

IV. 결 론

본 논문에서는 해상상태를 고려한 부유형 풍력 블레이드의 정상 및 불균형 회전 상태를 구분하기 위하여 수치해석 시뮬레이션과 24GHz 도플러 레이더를 이용한 실내 측정, 실외 측정을 통하여 데이터를 획득한 후 훈련 데이터와 테스트 데이터를 7:3으로 나누어 구분 실험을 진행하였다. 이때 훈련 데이터는 잡음이 없는 데이터를 이용하였으며, 테스트 데이터는 SNR이 각각 5, 10, 15, 20dB일 때, 가우시안 노이즈를 추가하여 실험을 진행하였다. 그 결과 SNR이 증가함에 따라 구분 정확도가 향상되며, 5dB에서는 92.1%, 20 dB에서는 98.1% 이상의 구분 정확도를 확인할 수 있었다. 이를 통해 3가지 방법 모두에서 도플러 레이더를 이용한 풍력 블레이드의 회전 상태 구분이 가능한 것을 확인할 수 있었다. 본 논문은 실제 부유형 풍력 터빈을 측정하고 진행한 연구가 아니므로 향후 실제 부유형 풍력 터빈의 회전상태를 측정하여 실험을 진행할 예정이다.

Acknowledgement

본 논문은 2023년 개최된 한국정보기술학회 하계 종합학술대회에 발표된 논문 “해상상태를 반영한 부유형 풍력터빈의 회전상태 구분[11]”을 확장한 것이다.

References

- [1] K. Hwang and T. Xiaolong, "GHG Emissions in Korea's Renewable Energy Power Generation Sector's Calculation and Factor Analysis", The Society of Convergence Knowledge Transactions, Vol. 10, No. 4, pp. 111-119, Dec. 2022. <https://doi.org/10.22716/sckt.2022.10.4.041>.
- [2] B. J. Kim, S. Y. Lee, Y. D. Ahn, and S. J. Kang, "Wind Turbine Blade Fault Diagnosis System Using Machine Learning", Proc. of 2017(48th) KIEE Summer Conference, Busan, Korea, pp. 1498-1499, Jul. 2017.
- [3] K. Oh, J. Park, J. Lee, B. I. Epureanu, and J. Lee, "A Novel Method and its Field Tests for Monitoring and Diagnosing Blade Health for Wind Turbines", IEEE Transactions on Instrumentation and Measurement, Vol. 64, No. 6, pp. 1726-1733, Jun. 2015. <http://dx.doi.org/10.1109/TIM.2014.2381791>.
- [4] C.-H. Kim, I.-S. Paek, N.-S. Yoo, and Y.-S. Nam, "Modal Analysis of a Wind Turbine Blade using FBG Sensors", Proc. of 2010 KSME spring conference, Gwangju, Korea, pp. 428-430, May 2010.
- [5] C. C. Chen, J.-R. Lee, and H.-J. Bang, "Structural Health Monitoring for a Wind Turbine System: a Review of Damage Detection Methods", Measurement Science and Technology, Vol. 19, No. 12, pp. 1-20, Oct. 2008. <https://doi.org/10.1088/0957-0233/19/12/122001>.
- [6] B.-J. Kim, S.-W. Choi, and S.-J. Kang, "Motion Vector Estimation System For Detecting Wind Turbine Blade Break", The 2016 47th KIEE Summer Conference, Pyeongchang, Korea, pp. 13-15, Jun. 2016.
- [7] B. Y. Lee, "Introduction of automatic check process of wind turbine using small drones", The magazine of for Aeronautical and Space Sciences, Vol. 17, No. 1, pp. 24-37, Feb. 2023.
- [8] Y.-B. Kim, Y.-M. Kim and I.-S. Choi, "State Classification of Wind Turbine Blade using Convolutional Neural Network", Journal of Korean Institute of Information Technology, Vol. 20, No. 4, pp. 89-97, Apr. 2022. <http://dx.doi.org/10.14801/jkiit.2022.20.4.89>.
- [9] Y. M. Kim and I. S. Choi, "Comparison of Numerical Analysis and Indoor Measurement for Floating Wind Turbine Blade", Proc. of KIIT Conference, Jeju, Korea, pp. 311-312 Jun. 2022.
- [10] S. T. Kim, Y. M. Kim, S. Y. Kim, S. W. Kim and I. S. Choi, "Infant Care System Using Emotional Recognition and Sensors", Proc. of the 2022 KIIT Conference, Jeju, Korea, pp. 337-338, Dec. 2022.
- [11] E. B. Kim and I. S. Choi, "Rotation State Classification of Floating Wind Turbine Considering Sea state", Proc. of the 2023 KIIT summer Conference, Jeju, Korea, pp. 760-761, Dec. 2023.
- [12] J.-J. Lee, W.-J. Lim, S.-B. Jung, U.-J. Jung, and G.-J. Park, "Structural Optimization of the Mobile Harbor Crane Considering Sea State", Journal of the Computational Structural Engineering Institute of Korea, Vol. 25, No. 1, pp. 27-36, Feb. 2012. <https://doi.org/10.7734/COSEIK.2012.25.1.027>.
- [13] S. W. Ryu, Y. M. Kim, Y. M. Kim, Y. B. Kim, and I. S. Choi, "Design and Fabrication of 3D Motion Platform with Coning motion", The Journal of Korean Institute of Electromagnetic Engineering and Science, Vol. 22, No. 1, pp. 38-39, Oct. 2021.
- [14] J. W. Bae and I. S. Choi, "Analysis of Indoor Measurement Result for Floating Wind Turbine by Sea State", Proc. of the 2023 KIIT Conference, Jeju, Korea, pp. 727-728. Jun. 2023.

- [15] Y.-J. Choi and I.-S. Choi, "Dynamic RCS Calculation of Wind Turbine Blade Using GPU-Based TSM-RT", The Journal of Korean Institute of Electromagnetic Engineering and Science, Vol. 31, No. 3, pp. 245-252, Mar. 2020. <http://dx.doi.org/10.5515/KJKIEES.2020.31.3.245>.

저자소개

김 응 빈 (EungBeen Kim)



2018년 3월 ~ 2024년 2월 :
한남대학교 전기전자공학과
(공학사)
2024년 2월~ : Sensorpia 사원
관심분야 : 레이더 신호 측정 및
분석, 레이더 신호처리

최 인 식 (In-Sik Choi)



1998년 2월 : 경북대학교
전자공학과(공학사)
2000년 2월 : POSTECH
전자전기공학과 (공학석사)
2003년 2월 : POSTECH
전자전기공학과 (공학박사)
2003년 ~ 2004년 : LG전자

선임연구원

2004년 ~ 2007년 : 국방과학연구소 선임연구원
2007년 ~ 현재 : 한남대학교 전기전자공학과 교수
관심분야 : RADAR 신호처리, RADAR 시스템 설계,
RCS 해석 및 분석, EMI/EMC 해석