

# 풍력발전기 진동 데이터를 활용한 딥러닝 기반 고장진단기법 연구

정성목\*, 최우진\*\*

## A Study on Deep Learning-based Fault Diagnosis using Vibration Data of Wind Generator

Sung-Mok Jung\*, Woo-Jin Choi\*\*

---

본 연구는 2020년도 중소기업기술혁신개발사업의 재원으로 중소벤처기업부(TIPA)의 지원을 받아 수행한 연구과제(No. S2866138)임.

---

### 요 약

본 연구에서는 고장 진단을 위해 수집된 진동 신호의 특징 선택 및 추출을 통해 풍력발전기에 발생하는 고장 유형을 자동으로 진단하는 기계학습 모델의 개발을 수행하였다. 진동 데이터의 경우 실제 운영되고 있는 풍력발전기에서 수집하였고, 실제 고장으로 검증된 데이터를 고장 유형별로 레이블링하였으며, 특히 특징 추출의 경우 풍력발전기의 대부분의 고장 진단이 가능한 주파수 영역에서 추출하였다. 고장 진단에서의 진동 분석은 대부분이 주파수 영역에서의 패턴 및 진동 크기로 평가한다는 점을 고려하였으며, 여러 가지 기계학습 알고리즘 중 인공신경망(ANN, Artificial Neural Networks)을 선정하여 풍력발전기의 진동 데이터를 이용한 고장 분류 모델을 평가하였다. 9,800개의 진동 데이터셋을 이용하여 기계학습을 하고 유효성 검증을 수행한 결과, 정확도 99.6%의 분류 정확도를 가졌다.

### Abstract

In this study, a machine learning model was developed to automatically diagnose the type of failure issued to wind power generators through the selection and extraction of the characteristics of the collected vibration signals.

Vibration data in this study were collected from wind power generators actually operating, and failure data for each type that actually occurred were labeled. In particular, the frequency range of feature extraction was extracted within the range within which most failures in wind power generators could be diagnosed. Vibration analysis in failure diagnosis considered that most of the vibration analysis is evaluated by pattern and vibration magnitudes in frequency domain, and artificial neural networks (ANN) were selected from various machine learning algorithms to evaluate a fault classification model using actual vibration data of wind power generators. As a result, machine learning using a vibration dataset of 9,800 was performed and the validation was performed, and the classification accuracy was 99.6%.

### Keywords

deep learning, machinery fault diagnosis, vibration analysis, wind generator

---

\* (주)브이엠에스 기술연구소 책임연구원

- ORCID: <https://orcid.org/0000-0003-1483-923X>

\*\* (주)브이엠에스 기술연구소 연구소장(교신저자)

- ORCID: <https://orcid.org/0000-0002-2424-8954>

• Received: May 27, 2022, Revised: Jun. 21, 2022, Accepted: Jun. 24, 2022

• Corresponding Author: Woo-Jin Choi

VMS Co., Ltd., Busan, Haeundae-gu, Centum jungang-ro 90, QB Centum, 1106, Korea.

Tel.: +82-51-782-2362, Email: [wjchoi@vmsco.co.kr](mailto:wjchoi@vmsco.co.kr)

## 1. 서 론

최근 7개국(G7) 정상회의에 주요한 이슈로 떠오른 탄소 중립(Carbon neutral) 문제로 우리나라 역시 국가 온실가스 감축목표(NDC)를 상향하는 방안이 대두되고 있다. 온실가스를 감축하기 위해 우리나라 전기 생산의 약 37%를 차지하는 석탄화력발전을 다른 에너지원으로 대체하기 위해 원자력발전 및 신재생에너지가 해결책으로 떠오르고 있으며 그 중 원자력발전의 경우 우리나라는 원전 밀집도 세계 1위, 개별 원전 부지별 밀집도 및 규모 세계 1위 등의 불명예를 안고 있으며 지금보다 더 많은 원전을 추가하는 것은 후쿠시마 사고보다 더 큰 위험을 초래할 수 있다.

따라서 신재생에너지인 태양광 및 풍력이 각광받고 있으며 특히 바람 에너지를 이용한 풍력발전은 세계적으로도 대체에너지로서 주목받고 있다. 그런데 풍력발전기의 경우 다른 발전설비와는 다르게 다수의 설비가 넓게 분포되어 있고 중요 설비가 있는 너셀(Nucell)의 경우 지상으로부터 50m ~ 100m에 위치하고 있어 설비 관리가 쉽지 않다. 특히 해상풍력발전기의 경우 고장 발생 시 풍속과 파고에 따른 접근 문제로 설비 관리의 어려움은 더욱 크다.

이러한 문제로 인해 중대 사고 예방 및 설비 관리를 위한 부품 고장을 조기에 감지하여 정비계획을 수립하는 것은 거의 필수적이며 이를 위해 고장 진단 상태 감시 시스템에 관한 연구가 활발히 이루어지고 있으며 특히 진동 센서를 이용하여 상태 감시(CM, Condition Monitoring) 시스템은 풍력발전기의 너셀 내 주요 부품인 Main Bearing, Gearbox, Generator 등의 회전 기계의 고장 진단에 적합하다고 알려져 있고, 이를 위한 상태 감시 및 진단 기법도 국내에서 활발히 연구되고 있다[1][2].

상태 감시를 통한 예방정비의 경우 일반적인 산업체에서는 상태 기반 정비(CBM, Condition Based Maintenance)와 고장 예지 및 건전성 관리(PHM, Prognostics and Health Management) 등이 많이 활용되고 있으나 풍력발전기의 예비 정비의 경우 이러한 정비기법 등의 도입이 아직 기초적인 수준에 머물고 있어 실제 고장 발생 시 막대한 손실을 발생시키고 있다.

Computing 기술의 급속한 발달로 인해 대용량 데이터 수집 및 그래픽처리장치(GPU)를 이용한 연산 능력 향상으로 인해 우수한 성능을 가진 기계학습 알고리즘이 급속하게 발전함에 따라 이를 이용한 지능형 공장(Smart factory) 구현에 많은 산업체에서 관심과 노력을 기울이고 있으며 풍력발전기 산업에도 예외는 아니다. 특히 여러 가지 특성상 설비 관리가 어려운 풍력발전기의 경우에는 진동 데이터를 활용한 고장 진단 시스템 구축이 필수적이다. 진동을 활용한 고장 진단의 경우 시간 영역 분석, 주파수 분석 등이 활용되고 있으나 이는 진동 분석 전문가가 아니고서는 실제 분석이 어렵다. 따라서 진동 데이터를 이용한 고장진단 기술에 인공지능 기술이 융합된다면 누구나 쉽게 고장 진단이 가능하며 설비 고장에 대한 신속한 대응 체계를 수립할 수 있을 것으로 판단된다[1].

본 연구에서는 고장 진단에 효율적인 진동 데이터의 특징을 이용하여 풍력발전기의 다양한 고장 유형에 대해 알맞은 인공지능 모델을 선정하고 이에 대해 분석하여 논의한다. 학습되지 않은 데이터를 제시된 고장 유형으로 분류하기 위해 다년간 수집된 풍력발전기의 실제 진동 데이터 중에 효율적인 특징을 선택 및 추출하였고 다양한 고장 유형에 따른 분류 모델을 선정하였다[3][4]. II장에서는 풍력발전기의 진동 고장 진단 방법 및 진동 데이터의 특징에 대하여 설명하고 있고, III장에서는 데이터의 특징 선택, 특징 추출 방법, 다양한 고장 유형, 인공지능 모델의 선정 및 연구에 대하여 설명한다. IV장에서는 결론 및 향후 과제에 대하여 설명한다.

## II. 풍력발전기 고장 진단 방법 및 진동 데이터의 특징

### 2.1 풍력발전기 고장 진단 방법

풍력발전기는 풍속과 풍향에 대해 최적의 출력을 생산하도록 제작된 설비이다. 따라서 풍속에 의해 너셀 내 회전체 설비의 회전 속도가 결정되며 일반적으로 풍속 3 ~ 25m/s의 가변 구간과 정속 구간이 존재하며 정속 구간이 가변 구간보다 상대적으로

신호처리 및 진단분석이 용이한 편이라 정밀진단 분석에 사용된다.

ISO 13372:2004에서는 고장진단을 상태감시와 진단으로 나누어 정의하는데, 상태감시는 간이 진단에 대응하고, 진단은 정밀진단에 대응하는 개념으로 이번 연구는 두 가지 개념 모두에 적용된다.

풍력발전기의 진동 분석 절차는 그림 1과 같이

구성되며 센서는 발전기 내 주요 위치에 그림 2와 같이 부착된다. LTE 무선 통신을 통해 진동 신호를 데이터 서버로 전송하여 진동 분석을 실시하였다 [3][4]. 이때 풍력발전기의 이상징후가 발견된다면 설비 점검 및 보전 작업을 실시하여 고장의 유형에 대해 파악한 후 설비 점검 전/후의 진동 데이터 차이를 통해 분석 결과의 타당성 여부를 검증하였다.

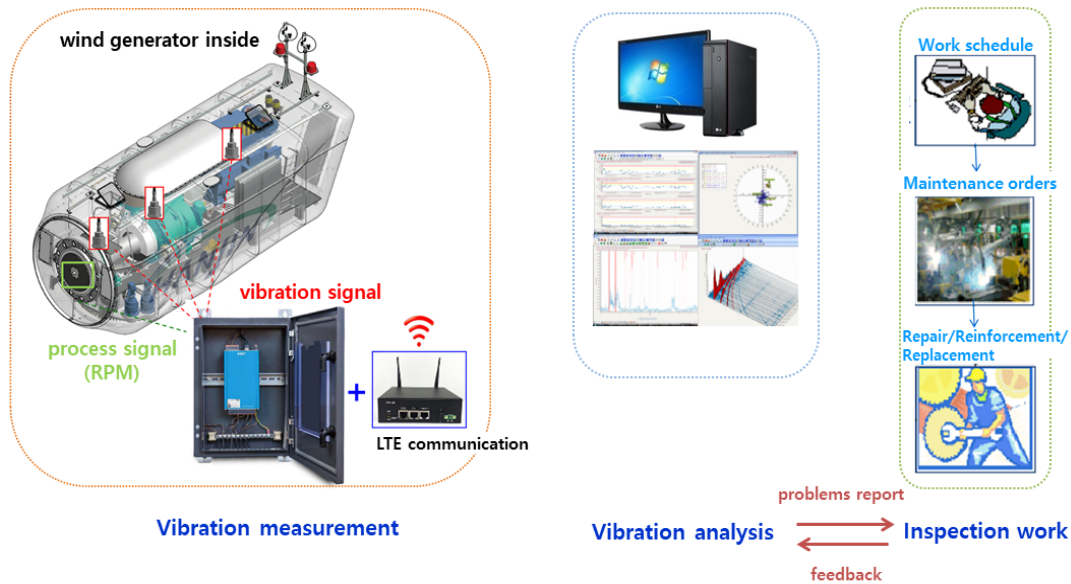


그림 1. 풍력발전기에 대한 진동 분석 절차  
Fig. 1. Vibration analysis procedure for wind turbine




그림 2. 풍력발전기의 진동 센서 위치  
Fig. 2. Location of the vibration sensor of the wind turbine

## 2.2 진동 데이터의 특징

진동 분석은 장비의 작동 및 기계적인 상태를 결정하는 것에 사용되며 여러 가지 보전 기술 중에 회전 기계의 결함을 검출하는 데 가장 효과적인 기술로 알려져 있다[1]. 고장 진단에서 중요한 것은 설비의 문제가 심각해지기 전에 문제를 파악하여 예기치 않은 Downtime을 막아야 한다는 것이며 이런 이유로 그림 3 및 표 1과 같이 진동 분석은 조기에 문제를 파악할 수 있고 가장 많은 고장 유형을 동시에 검출할 수 있다는 점에서 고장 진단에 널리 활용되고 있다.




그림 3. 잠재적 고장 곡선  
Fig. 3. Potential failure curve

표 1. 고장 진단 기술별 결함 검출 리스트  
Table 1. List of fault detection by fault diagnosis technology

Sensor Fault	Temperature	Pressure, flow	Lubricating oil	Ultrasonic	Vibration
Unbalance					○
Misalignment	○				○
Bearing	○	○	○	○	○
Gear defect			○	○	○
Assembly				○	○
Acoustic noise				○	○
Shaft crack					○
Resonance					○

한편, 진동 분석의 경우 누구나 쉽게 분석하기가 어려워 진동 분석 전문가가 필요로 하고 또한 전문가 역시 다음과 같은 이유로 육안으로 분석하는 것에 한계를 느낀다[1].

- 1) 회전 기계의 모든 Waveform 신호가 시각적으로 명확한 차이를 제공하지는 않는다.
- 2) 진동 분석에서 종종 노이즈가 포함된 다량의 진동 신호를 수집하고 분석해야 한다.
- 3) 때때로 노이즈에 대하여 낮은 진폭의 신호를 처리해야 한다.
- 4) 조기에 결함을 감지해야 하므로 진동 분석 기술이 요구된다. 하지만 모든 진동 신호를 수동으로 검사할 경우 시간이 많이 걸린다.
- 5) Human Error가 존재한다.

따라서 상기의 문제를 해결하기 위해 고장 진단에서 인공지능을 활용하여 자동으로 고장 감지가 되는 연구가 활발히 이루어지고 있고 여러 가지 문헌에서는 다양한 기계학습 알고리즘의 적용을 언급했다[2][5][6].

문헌에서는 다양한 분류 기술을 사용한다면 특징을 가진 다양한 진동 유형을 분류할 수 있으며 높은 정확도 역시 달성할 수 있다고 한다[1].

## III. 딥러닝 기반 고장진단기법 연구

### 3.1 특징 선택 및 추출

진동 신호에는 대량의 노이즈 신호도 함께 수집되므로 다양한 기계학습 알고리즘을 이용하여 자동으로 노이즈를 삭제하는 것은 차원의 저주 문제로 쉬운 작업이 아니다[1]. 따라서 특징을 선택하고 추출하는 것은 중요한 문제이다. 특징을 선택하기 위해서는 분류에 대한 1) 높은 관련성 2) 낮은 관련성 3) 관련 없는 특징을 고려해야 한다. 그 이유는 고차원의 데이터를 신호처리를 하기 위해 많은 저장 공간 및 시간이 요구되기 때문이며 관련 없는 특징의 경우 분류 정확도에는 절대적으로 기여할 수 없는 반면, 관련 있는 특징은 높거나 낮더라도 분류 정확도에 기여할 수 있다. 즉 해당 특징을 제거한다면 분류 결과가 변할 수 있음을 의미한다. 다음의 표 2는 풍력발전기의 고장 유형을 분류하여 레이블링 번호를 부여한 것이다.

표 2. 풍력발전기 고장 유형 분류 및 레이블링 번호  
Table 2. Wind turbine failure type classification and labeling number

No.	Fault frequency	Meaning of an abbreviation
0	Normal	Normal condition
1	1x	Unbalancing, assembly, resonance
2	2x	Misalignment of the shaft
3	GMF	Faulty gearbox 1
4	BPFI	Bearing ball pass frequency for inner race
5	BPFO	Bearing ball pass frequency for outer race
6	Loose	Mechanical looseness, softfoot

이것을 기준으로 다음의 그림 4와 같이 고장 유형에 따른 데이터를 분류하였다.

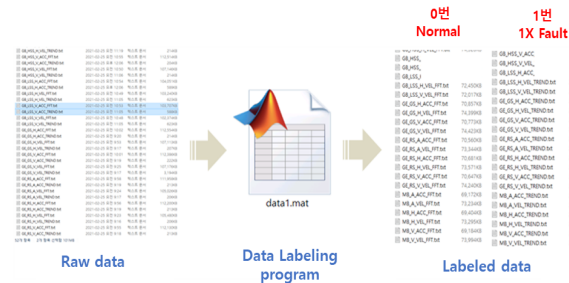


그림 4. 고장 유형에 따른 데이터 라벨링  
Fig. 4. Data Labeling by failure type

### 3.2 딥러닝 알고리즘 연구

#### 3.2.1 알고리즘 선정 배경

고장 진단을 위한 주파수 분석의 경우 주파수 영역에서 주파수 및 진폭에 의해 결함 유형 및 고장 심각도를 결정한다. 특히 주파수에 따른 결함 패턴은 고장 유형을 결정하는 데 있어 결정적인 영향을 미치는 요소이다. 풍력발전기의 경우 그림 5는 그 예로서 원으로 표시한 특징이 실제 고장 유형에서 베어링 내륜 결함에 해당한다. 이러한 주파수 패턴 특징으로 고장의 유형을 결정할 수 있는 것을 알 수 있다[7]-[10].

그림 6은 본 논문에서 분류하고자 하는 정상상태 및 6가지 유형의 결함에 대한 대표적인 주파수 영역의 데이터 패턴을 나타낸다.




그림 5. 결함을 의미하는 주파수 패턴

Fig. 5. Fault frequency pattern

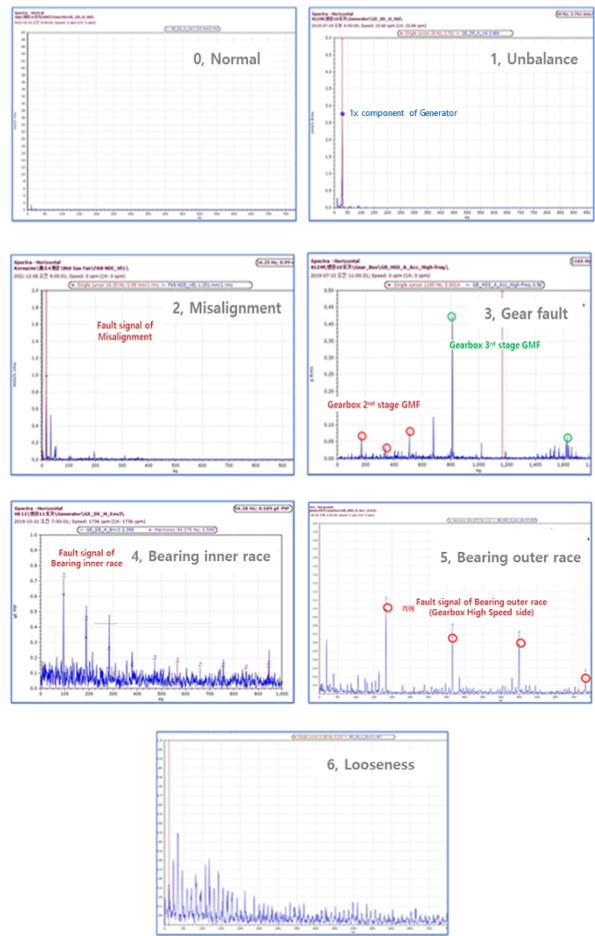


그림 6. 정상 상태 및 6가지 유형의 결함 데이터  
Fig. 6. Normal condition and 6-types of fault data

이러한 고장 패턴은 고장 유형을 분류하는 데 있어 중요한 인자로 표현되며 이와 유사한 특성을 이용하는 것이 이미지 분류 기법이다. 이미지 분류에 있어 큰 장점이 있는 알고리즘 중의 하나가 인공 신경망을 이용하는 딥러닝 알고리즘이며 이것을 회전 기계의 고장진단에 응용할 수 있다[11]-[14].

3.2.2 알고리즘 연구

풍력발전기의 고장 유형별 진동 데이터의 경우 그림 7과 같은 Work Flow를 토대로 연구를 진행하였다. 딥러닝 연구/개발을 위해서는 목적에 맞는 프레임워크 선정이 중요하다. 본 연구에서는 최근 각광을 받고 있는 텐서플로를 이용하여 딥러닝 네트워크를 구성하였다. 텐서플로(TensorFlow)는 CPU와 GPU를 사용해 인공 신경망 모델을 효율적으로 훈련하게 하며 모델 구축과 서비스에 필요한 다양한 도구를 제공한다[11].

전체적인 네트워크 구조는 Weight/Bias/Relu를 하나의 레이어로 구성하여 5층의 레이어로 네트워크를 설계하였고 최종적으로 Softmax를 이용하여 최종 확률을 계산하도록 제작하였다. 최초 입력은 레이블링 된 진동 데이터를 사용하였고, 그 입력값이 네트워크 구조를 따라서 차례대로 다음 레이어로 전달된다. 각 레이어에서는 반복적인 학습 과정을 거쳐서 각 레이어에서의 Weight, Bias 값들이 결정되고 그 데이터는 저장해 두었다가 새로운 데이터가 입력되었을 때 그 확률값을 최종 Softmax 레이어에서 계산하여 최종 분류 결과를 확인하도록 하였다.

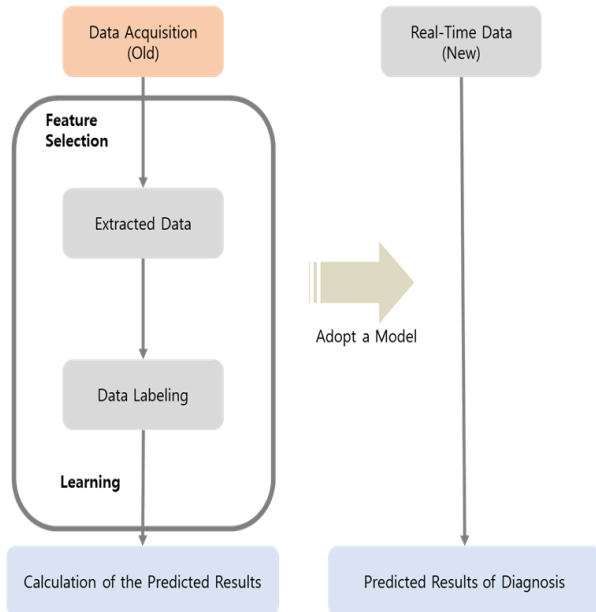


그림 7. 워크플로 요약  
Fig. 7. Workflow summary

최적화는 Adam 알고리즘을 활용하여 Cost 함수 값을 최소화 하도록 하였다. 그림 8과 같이 반복 횟수가 약 1,000번까지 진행된 경우 Cost 함수값이 줄어들어 0에 근접하였다. 학습에 사용한 전체 데이터셋은 9,800개이며 이 중 1,000개의 데이터를 확인용 데이터셋으로 사용하였다. 알고리즘의 유효성을 검증하기 위하여 학습용 데이터셋 및 확인용 데이터셋의 비율은 일반적으로 많이 사용하는 8:2의 비율로 선정하였으며 정확도는 99.6%를 나타내었다.

또한, 그림 9는 확인용 데이터셋을 입력했을 때 무작위로 선택된 데이터를 인공지능 시스템이 어떻게 분류했는지 보여주는 그래프이다.

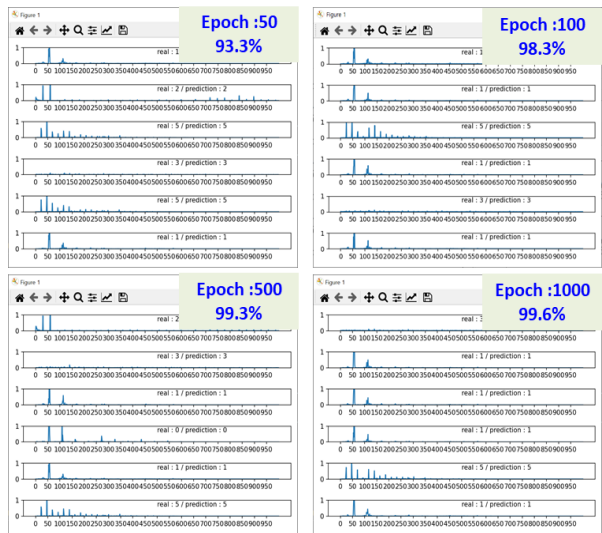


그림 8. Epoch에 따른 정확도  
Fig. 8. Accuracy according to epoch

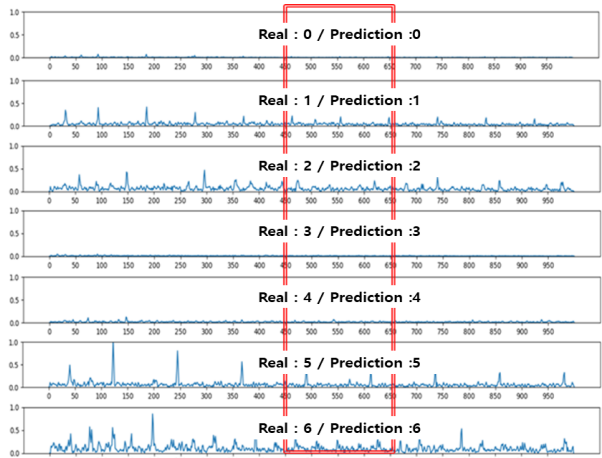



그림 9. 정상 상태 및 6가지 유형의 결함 데이터  
Fig. 9. Normal condition and 6-types of fault data

해당 그래프에서 제시된 결과를 살펴보면 레이블링 번호 0/3/4의 경우 사람의 눈으로 보기에는 그 차이를 구분하기 힘들지만 딥러닝 알고리즘을 이용하면 정확하게 각 고장 유형을 분류하는 것을 확인할 수 있다.

다음의 그림 10은 레이블링된 정상 및 6가지 고장유형에 따른 진단 결과의 정확도를 매트릭스 형태로 나타낸 것이다.



L ID	mode ID	Accuracy
0	normal	100%
1	1x	100%
2	2x	100%
3	GMF	100%
4	BPFI	100%
5	BPFO	93%
6	Loose	100%

그림 10. 고장 유형에 따른 정확도 평가  
Fig. 10. Accuracy evaluation according to failure type

#### IV. 결론 및 향후 과제

본 연구에서는 실제 풍력발전기의 진동 신호를 수집하여 데이터 학습을 통해 풍력발전기의 고장 유형을 분류하는 기계학습 기반의 고장 분류 모델

을 개발하였다. 학습에 이용한 진동 데이터는 풍력 발전기에서 다년간 수집하여 정상 및 고장이 검증된 데이터를 이용하였으며, 개발한 분류 프로그램을 통해 정상 및 고장 유형에 따른 데이터로 분류하였다. 이때 고장 분류를 위해 높은 연관성이 있는 주파수 영역의 속도 및 가속도 진동을 선택하여 진행하였다. 기계학습 알고리즘의 경우 주파수 영역의 진동 패턴을 기반으로 진동 분석을 한다는 점을 고려하여 이미지 분류 문제에 있어 큰 장점을 가지고 있는 인공지능망을 이용하여 고장 분류를 수행하였다. 9,800개의 진동 데이터셋을 이용하여 기계학습을 하였고 유효성 검증을 수행한 결과, 정확도 99.6%의 분류 정확도를 가졌다.

앞으로 본 연구의 신뢰성 향상을 위해 평가된 학습 모델을 운전 중인 풍력발전기에 실제 적용하고자 한다. 그리고, 고장 분류 모델에서 진동 데이터 이외의 특성(소음, 온도 등)을 선정하여 진단의 신뢰도를 높이고 특성들의 타당성을 검토하고자 한다. 이들 연구가 충분히 진행되고 나면 풍력발전기의 특성에 최적화된 기계학습 기반의 고장 진단 프로그램의 개발을 통하여 풍력발전 산업에 이바지할 수 있을 것으로 기대한다.

#### References

- [1] Hosameldin Ahmed and Asoke K. Nandi, "Condition Monitoring with Vibration Signals", Wiley-IEEE Press, pp. 117-130, 2019.
- [2] Liu R., Yang B., Zio E., and Chen X., "Artificial intelligence for fault diagnosis of rotating machinery: A review", Mechanical Systems and Signal Processing, Vol. 108, pp. 33-47, 2018. <https://doi.org/10.1016/j.ymssp.2018.02.016>.
- [3] Cornelius Scheffer and Paresh Girdhar, "Practical Machinery Vibration Analysis & Predictive Maintenance", Elsevier, pp. 89-133, 2004.
- [4] W. J. Choi, S. M. Jung, T. Y. Hong, and C. K. Lee, "Remote Real-Time Diagnostics for Wind Mill using Vibration Sensors", The 2019 Fall Conference of Korea Wind Energy Association, pp. 336-337, Oct. 2019.

[5] Martin-Diaz I., Morinigo-Sotelo D., Duque-Perez O., and Romero-Troncoso, R. J. "An experimental comparative evaluation of machine learning techniques for motor fault diagnosis under various operating conditions", IEEE Transactions on Industry Applications, Vol. 54, No. 3, pp. 2215-2224, 2018. <https://doi.org/10.1109/TIA.2018.2801863>.

[6] Zhao R., Yan R., and Chen Z., "Deep learning and its applications to machine health monitoring", Mechanical Systems and Signal Processing, Vol. 115, pp. 213-237, Jan. 2019. <https://doi.org/10.1016/j.ymssp.2018.05.050>.

[7] Steve Goldman, "Vibration Spectrum Analysis", Industrial Press Inc., pp. 1-25, 1999.

[8] B. S. Yang, "Failure analysis and diagnosis of induction motor using vibration signal analysis technology", GSinterview, pp. 9-11, 2019.

[9] ISO 10816-21:2015 Mechanical vibration, 2015.

[10] Mohammad Nurul Hoque and Sinin Hamdan, "Vibration Measurement of Rolling Element Bearing", LAP LAMBERT Academic Publishing GmbH & Co. KG, pp. 13-54, 2011.

[11] Solaris, "Deep Learning with TensorFlow", Youngjin.com Inc., pp. 97-117, 2018.

[12] VMS Co., "Fault diagnosis system of mechanical devices using autoencoder and deep-learning", Patent KR 10-2027389, Sep. 2019.

[13] Mohammakazem Sadoughi, Austin Downey, Garrett Bunge, Aditya Ranawat, Chao Hu, and Simon Laflamme, "A Deep Learning-based Approach for Fault Diagnosis of Roller Element Bearings", 2018 Annual Conference of the Prognostics and Health Management Society, Vol. 10, pp. 1-7, Sep. 2018. <https://doi.org/10.36001/phmconf.2018.v10i1.526>.

[14] S. J. Park and D. S. Kang, "Implementation of Real-time Monitoring System using the Neural Network for Automatic Failure Diagnosis of Offshore Wind Turbine", The Journal of Korean Institute of Information Technology, Vol. 10, No. 7, pp. 193-198, Jul. 2012.

## 저자소개

### 정 성 목 (Sung-Mok Jung)



2007년 2월 : 경성대학교  
환경공학부(공학사)  
2022년 2월 : 부산대학교 대학원  
ICT 융합학과(공학석사)  
2007년 11월 ~ 2011년 6월 :  
크리에이텍 주임연구원  
2014년 2월 ~ 현재 :

(주)브이엠에스 책임연구원

관심분야 : 회전설비 고장 진단, 인공지능, 회전체 진동 분석

### 최 우 진 (Woo-Jin Choi)



1994년 2월 : 동아대학교  
전기공학과(공학사)  
1996년 2월 : 동아대학교 대학원  
전기공학과(공학석사)  
2013년 8월 : 동아대학교 대학원  
전기공학과(공학박사)  
1996년 1월 ~ 2001년 11월 :

(주)사라콤 연구1팀장

2001년 12월 ~ 2017년 12월 : 한라IMS(주) 기술연구소장  
2018년 1월 ~ 2018년 10월 : 한라IMS(주) 연구위원  
2018년 11월 ~ 현재 : (주)브이엠에스 기술연구소장  
관심분야 : 인공지능, 퍼지이론, 뉴로-컨트롤러, 유전 알고리즘, 지능제어, 산업용 계측센서, 진동 분석