



# 2D CNN을 이용한 풍력발전기용 베어링의 결함 검출 연구

강태한<sup>1),2)</sup> · 황성목<sup>3)\*</sup> · 김대영<sup>4)</sup> · 오기용<sup>5)</sup>

## A Study on Fault Detection of Wind Turbine Bearings Using 2D CNN

Taehan Kang<sup>1),2)</sup> · Sungmok Hwang<sup>3)\*</sup> · Dae-Young Kim<sup>4)</sup> · Ki-Yong Oh<sup>5)</sup>

Received 12 December 2025 Revised 6 March 2026 Accepted 16 March 2026 Published online 20 March 2026

**ABSTRACT** This study simulated the defects that could occur in bearings when installed in wind turbines, conducted experiments, and detected them using a 2D CNN. Tapered roller bearings, which have similar characteristics to those of wind turbine bearings, were selected to overcome the limitations of accessing actual bearing data. In particular, four cases were simulated, including a normal bearing and three defective bearings corresponding to outer raceway, roller, and combined outer raceway defects. Furthermore, vibration data were collected by setting the load and rotational speed as variables to simulate the environmental changes caused by wind acting on the wind turbine. These collected data were analyzed using a 2D CNN-based model, and the model reliability was verified through cross-validation. The results were compared with those of SVM, KNN, and 1D CNN to verify the model performance. The results demonstrate that the proposed 2D CNN model can successfully detect bearing defects and is expected to be useful for diagnosing defects in bearings installed in actual wind turbines.

**Key words** Fault detection(결함 검출), 2D CNN(2D 합성곱 신경망), Wind turbine(풍력발전기), Main bearing(메인 베어링)

### Nomenclature

$y$  : output vector

$x$  : input vector

1) Research Student, Wind Energy Research Department, Korea Institute of Energy Research

2) Ph. D. Student, Department of Mechanical Engineering, Hanyang University

3) Assistant Professor, School of Mechatronics Engineering, KOREATECH

4) Ph.D. Senior Researcher, Wind Energy Research Department, Korea Institute of Energy Research

5) Associate Professor, Department of Mechanical Engineering, Hanyang University

\*Corresponding author: sm.hwang@koreatech.ac.kr  
Tel: +82-41-560-1617

$F(x, W_i)$  : residual mapping

$\sigma$  : activation function

$\hat{y}_j$  : predicted probability of j-th class

$\sigma(z)_j$  : softmax function

$z_j$  : logit for the j-th class

$K$  : total number of classes

$y_c$  : true label for i-th class

$\hat{y}_i$  : predicted probability for i-th class

TP : true positive

TN : true negative

FP : false positive

FN : false negative

## Abbreviation

- 1D CNN : 1D convolution neural network
- 2D CNN : 2D convolution neural network
- FFT : fast fourier transform
- HOG : histogram of oriented gradients
- KNN : K-nearest neighbor algorithm
- O&M : operation and maintenance
- STFT : short-time fourier transform
- SVM : support vector machine

## 1. 서론

풍력발전이란 바람의 운동에너지를 전기 에너지로 변환하는 시스템을 말한다. 기후 위기 극복을 위한 방법으로 풍력발전 산업은 육상에서 해상으로 설치 영역이 확장됨과 동시에 발전기의 대형화되는 방식으로 꾸준히 발전했다.<sup>[1]</sup> 일반적으로 풍력발전기의 O&M 비용은 약 17~34% 정도 되는데,<sup>[2]</sup> 풍력발전 산업의 성장은 유지보수 비용의 증가로 이어지고 있다.<sup>[3]</sup> Fig. 1에 의하면 풍력발전기의 메인 샤프트 혹은 베어링, 기어박스의 고장은 평균적으로 5개월 이상 풍력발전기의 작동을 중단시키며,<sup>[4]</sup> 기어박스에서는 베어링으로 인한 고장이 40%에 달한다.<sup>[5]</sup> 또한, 메인 베어링은 고장의 경우 장시간 풍력발전기의 가동 중단과 O&M 비용의 증가로 이어질 수 있는 주요 부품이기 때문에,<sup>[6]</sup> 사전에 결함을 검출하는 기술이 필요하다.




Fig. 1. Average downtime of components<sup>[4]</sup>

베어링의 결함을 사전에 검출하는 전통적인 방법으로 시간 영역의 통계 지표를 사용하는 진동 신호 분석이 있다. 수학적 계산이 간단하지만, 하중이나 속도 변화에 따른 값의 변동성이 커 효과적인 결함 검출이 불가능하다.<sup>[7]</sup> 이러한 한계를 극복하기 위해 등장한 표준 기법이 FFT로, 성분별로 신호를 분해하여 결함 주파수를 확인하는 방식이며 잡음이 많은 환경에서 다른 주파수에 의해 결함 주파수가 가려지는 문제가 있다. 그 예로 베어링 진단 사례에서도 결함 주파수 감지가 매우 어렵다는 것이 확인되었다.<sup>[8]</sup> 원본 FFT에서 식별하지 못한 신호를 식별하기 위해 포락선 분석 기법이 연구되었으나 분석자의 노하우에 의해서 분석 결과에 영향을 미친다는 한계가 있다.<sup>[9]</sup> 그러나 위와 같은 전통적인 방식은 최적 공진 대역을 찾는 노하우가 필요하거나 복잡하거나 잡음이 심한 신호에서는 최적 특징을 추출하기 어렵다는 한계로 인해 인공 지능을 기반으로 데이터의 특징을 직접 학습하고 결함을 검출할 수 있는 기법의 필요성이 대두되었다.

초기 인공 지능을 이용한 결함 검출 연구는 인공 신경망, SVM을 분류기로 활용했으며 이 과정에서 최적의 입력 특징, 분류기 파라미터를 탐색하는 자동화를 시도하였다. 그러나 위 방법 또한 분석자의 노하우가 영향을 미치고 새로운 특징을 학습할 수 없다는 한계가 존재했다.<sup>[10]</sup> 이후 딥러닝의 연구를 통해 수동 특징 추출 과정을 제거하고 진동 신호에서 직접 특징의 학습이 가능하게 됐다. 앙상블 딥 오토 인코더는 자동화 학습을 통하여 높은 정확도를 달성했으나 해당 기법은 단일 CNN 모델과 비교했을 때 훨씬 많은 계산 시간이 소요된다는 문제가 있으며, 실제 현장에서는 정상 데이터가 월등히 많은 불균형한 데이터 세트로 진단 성능이 떨어지는 문제를 가지고 있다.<sup>[11]</sup> 또한 결함 데이터의 부족은 성능에 큰 영향을 미치는데, 실제 풍력발전기에 설치되는 베어링의 결함 정보나 운용 정보는 공유가 되지 않기 때문에 결함 검출을 위한 데이터 수집이 어려운 문제가 있다.<sup>[12,13]</sup> 그에 따라서 본 연구는 베어링의 정보 없이도 결함을 검출할 수 있는 모델을 개발하였다.

본 연구에서는 2차원 합성곱 신경망을 이용하여 풍력발전기에 설치되는 베어링의 정확한 정보 없이도 결함을 검출할 수 있는 모델을 제안한다. 이를 위해 풍력발전기에 설치되는 테이퍼형 롤러 베어링을 선정하여 결함을 모사하고

발전기 운용 환경에 따라 베어링의 진동 신호를 측정하기 위한 실험을 수행하여 데이터를 수집한다. 수집된 데이터는 2D CNN 기반의 결함 검출 모델을 이용하여 결함을 검출하고 성능 확인을 위하여 3가지 다른 모델과 비교한다.

## 2. 실험 장치 및 방법

### 2.1 베어링 시편 선정


본 연구는 풍력발전기 핵심 부품 중 하나인 베어링에서 발생하는 초기 결함 검출을 위하여 진동 신호 분석 실험을 수행하였다. 풍력발전기 메인 샤프트는 구조적으로 축 방향 및 반경 방향의 하중을 복합적으로 받기 때문에 두 방향의 하중에 대해 동시에 지지가 가능한 테이퍼형 또는 스페리컬 롤러 베어링이 적용된다.<sup>[14]</sup> 베어링 결함은 시스템의 안정성을 저해하며 예기치 않은 발전기의 정지를 유발하며 이는 장시간 가동 중단으로 이어진다.<sup>[4]</sup> 특히 접근이 어려운 해상 풍력발전기의 경우 손실은 더욱 심각하다.<sup>[15]</sup> 따라서 본 연구에서는 실제와 같은 복합 하중 조건을 모사하기 위해 테이퍼형 롤러 베어링을 시편으로 선정하였다. 테이퍼형 롤러 베어링은 구조적으로 접촉각을 가지고 있어 복합 하중 지지에 유리하며 풍력발전기에서 발생하는 정렬 불량 조건을 모사하고 그에 따른 결함 메커니즘을 연구하기에 적합한 시편으로 외륜, 내륜, 롤러 그리고 케이지로 구성되어 있으며 자세한 사양은 Table 1에 표기하였다.<sup>[16]</sup>

베어링 결함은 발생하는 위치에 따라 각기 다른 고유한 특성 주파수를 가지기 때문에 기하학적 구조, 회전 속도, 그리고 결함 위치에 따라 다른 주파수가 나타난다. 또한, 진동 신호 분석을 통해 추출된 주파수 성분은 베어링 결함


의 종류, 위치를 식별할 수 있는 특징이 된다. 그에 따라 본 연구에서는 결함 검출 모델의 기초 모델을 확보하기 위해 정상상태의 베어링과 2종류의 단일 결함(외륜, 롤러), 1종류의 복합 결함(외륜 및 롤러) 총 4가지의 상태를 정의하고 모사하였다. Fig. 2는 선정된 베어링에서 모사한 결함의 형태와 크기로 (a)는 선정된 30308 테이퍼형 베어링의 외륜, 롤러에 각각 모사한 결함의 크기를 나타내었다. 외륜, 롤러에는 결함의 너비가 1 mm, 깊이는 0.5 mm, 폭은 외륜과 롤러의 전체 폭과 같도록 모사하였다. (b) - (d)는 모사한 외륜, 롤러 단일 결함, 그리고 외륜과 롤러의 복합 결함을 각각 표기하였다.

### 2.2 베어링 진동 실험

모사한 베어링의 결함 검출을 위한 진동 신호 분석 실험을 수행하였다. 또한 데이터의 재현성 확보를 위해 풍력발전기의 운전 환경을 모사할 수 있는 전용 베어링 진동 실험 장치를 구성하였다. Fig. 2는 각각 구동 장치와 베어링 시편을 설치하는 지그, 그리고 축 방향, 반경 방향에서 하중을 부여하는 액추에이터로 구성된 실험 장비로, 장치의 상



(a) Configuration of test bed



(b) Components of test bed

Table 1. The specification of Tapered Roller Bearing<sup>[16]</sup>

Specification	Value	Unit
Model number	30308	-
Inner diameter	40	mm
Outer diameter	90	mm
Width	23,25	mm
Contact angle	13	°
Static load rating	95	kN
Dynamic load rating	106	kN


Fig. 2. Bearing test bed model

Table 2. The specification of test bed

Specification	Value	Unit
Rated torque	48	Nm
Rated speed	1,500	RPM
Max. Force	50	kN

세한 제원은 Table 2에 기술하였다.

베어링 결함에 의한 진동 신호 측정을 위하여 압전형 가속도 센서(Dytran 3148E)를 선정하였다. 신호 왜곡을 최소화하고 일관된 결과를 보장하기 위해 센서는 Fig. 4와 같이 축 방향 1개, 반경 방향 2개씩 장비의 전, 후방에 부착하였다.



(a) Position and size of the fault



(b) Outer-race fault



(c) Roller fault



(d) Outer-race & roller fault

Fig. 3. The type of bearing fault




Fig. 4. Attachment position of vibration sensors

본 연구에서는 Fig. 3의 4가지 베어링 시편을 장비에 장착한 후 재현성 확보 및 일관된 데이터의 수집을 위하여 10분간 구동 모터의 공회전을 통해 윤활 상태 및 시스템을 안정화하여 실험을 수행하였다. 또한 풍력발전기 운영 환경 모사를 위하여 하중과 회전 속도를 변수로 설정하였다. 축 방향 및 반경 방향 하중은 각각 6단계(무하중, 2 kN, 4 kN, 6 kN, 8 kN, 10 kN)로 인가하였고, 베어링 회전 속도는 4단계(300 RPM, 600 RPM, 900 RPM, 1200 RPM)로 설정하였다. 베어링 상태별로 설정된 하중 및 속도 조건에 도달하면 연결된 DAQ 시스템을 통해 진동 신호를 측정하였다. 실험은 조건 별로 동일한 베어링을 2개씩 사용하였고, 데이터의 신뢰도 확보를 위하여 각각 2회씩 반복 측정을 수행하였다.

Fig. 5에 나타난 바와 같이 실험 데이터를 구축하였으며 측정된 신호는 NI-9234 DAQ 모듈과 NI-9189 새시를 통해 5120 Hz의 주파수로 샘플링되고 LabVIEW를 통해 수집되었다.

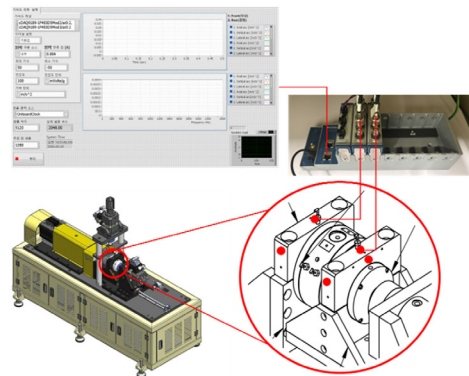


Fig. 5. Schematic of data acquisition process

### 3. 제안한 결함 검출 모델

#### 3.1 결함 검출 모델

본 연구에서는 베어링의 결함 검출 모델로써 2D CNN을 이용하였으며 모델 성능의 비교를 위하여 SVM, KNN 알고리즘, 1D CNN과 비교하였다. 수집된 실험 데이터는 Fig. 6과 같이 입력 데이터의 형태에 따라 1차원 진동 시계열 신호와 STFT 스펙트로그램 이미지로 구축하였다.

본 연구에서는 동일한 2세트의 베어링 데이터를 학습 데이터와 시험 데이터로 분할하여 결함을 검출하는 모델을 구현하였다. 그에 따라 데이터는 결함 상태로 분류된 각 조건별 데이터에서 5초 단위로 분할하고 결측치를 제거하여 각각 2,299개의 유효한 1차원 진동 시계열 신호와 STFT 스펙트로그램을 확보하였다. 모델의 구현을 위하여 1개의 베

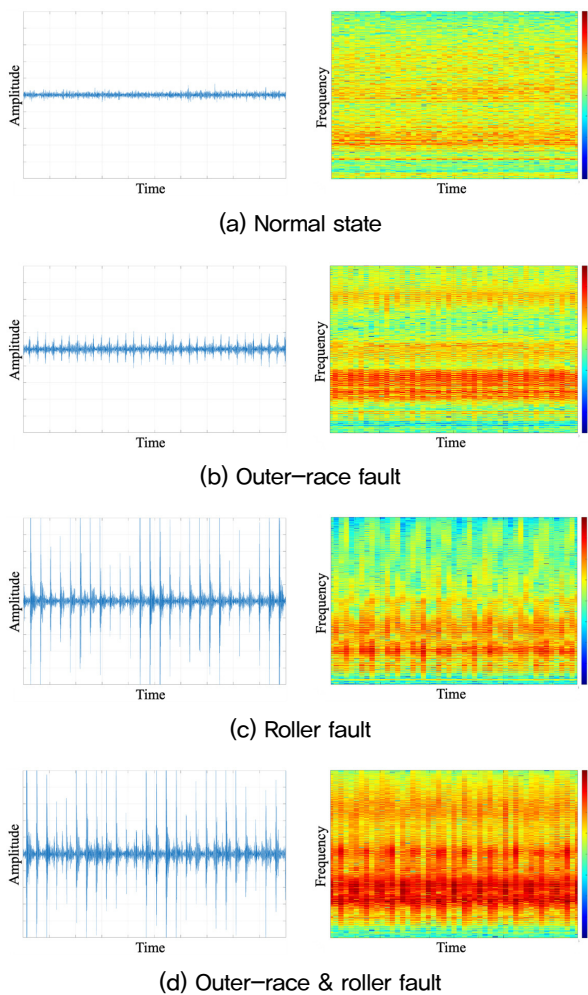


Fig. 6. Vibration signal and Spectrogram image

어링에서 측정된 1,152개(50%)의 1차원 진동 시계열 신호와 2차원 스펙트로그램 데이터에서 1,037개(45%)의 학습 데이터(train data)와 115개(5%)의 검증 데이터(validation data)로 무작위로 선택되어 하이퍼 파라미터 최적화를 수행하였다. 최적화된 하이퍼 파라미터를 이용하여 학습하지 않은 데이터 1,147개(50%)를 통한 결함 검출 모델의 성능을 확인하였다.

본 연구에서는 STFT 변환을 통해 생성된 2차원 스펙트로그램 이미지를 입력으로 사용하며, 위 이미지의 구조적 특징을 처리하는 방식에 따라 SVM, KNN, 1D CNN, 2D CNN의 성능 차이를 분석한다.

전통적인 기계학습 모델인 SVM, KNN은 딥러닝과 달리 이미지 자체를 학습하기 어렵기 때문에 수동으로 특징을 추출하는 과정이 필수적이다. 이를 위해 두 모델은 HOG 알고리즘을 사용하여 스펙트로그램의 지역적 기울기와 형태 학적인 특징을 추출하고 이를 1차원 벡터 형태로 변환하여 입력 데이터로 사용한다. SVM은 추출된 특징을 기반으로 클래스 간 마진을 최대화하는 결정 경계(Decision boundary)를 학습한다. 위 방법은 과적합에 강하고 전역 최적해를 보장하지만, 1차원 벡터화 과정에서 시간-주파수 축의 인접 정보가 소실되며 대용량 데이터 처리 시 효율이 떨어지는 한계가 있다. KNN 모델은 추출된 특징 벡터를 특징 공간에 매핑하여 참조 데이터베이스를 구축하는 방식으로 학습하며 별도의 학습 과정이 없어서 유지보수가 쉽지만, 추론 시 모든 데이터와의 거리를 계산해야 하기 때문에 계산 속도가 느리고 고차원 특징 공간에서 차원의 저주에 취약하다는 한계가 존재한다.

기존 머신러닝 기법과는 다르게 딥러닝 기반의 1D CNN은 스펙트로그램 이미지가 아닌 진동 시계열 신호를 직접 학습하는데, 이 모델은 1차원 합성곱 필터를 사용하여 결함 발생 시 나타나는 주기적인 충격이나 진폭 변화와 같은 시간적 패턴을 중점적으로 추출하고 학습한다. 연산 효율성이 뛰어나다는 장점이 있으나 주파수 대역 간 상호작용이나 스펙트로그램 전체에서 나타나는 복잡한 2차원 텍스처 정보를 활용하지 못해 복잡한 결함 패턴 분석에는 정보 손실이 발생할 수 있다.

마지막으로 2D CNN은 스펙트로그램 이미지를 입력으로 사용하며 2차원 합성곱 필터를 통해 이미지의 공간적,

지역적 특징을 스스로 추출하고 학습한다. 이는 HOG와 같은 수동 특징 추출 과정 없이도 시간-주파수 영역의 상관 관계를 보존하며, 풀링 레이어를 통해 신호의 위치 변화나 노이즈에 강건한 이동 불변성을 확보한다. 높은 연산 비용이 들지만, 데이터의 고유 형상을 정확하게 인식할 수 있다는 장점이 있다.

Fig. 7에 표기한 바와 같이 제안하는 검출 모델은 ResNet-18의 2D CNN 모델을 기반으로 설계되었다. 해당 모델은 스펙트로그램 이미지를 입력 신호로 받아 시각적 패턴을 추출하고 결함 유형을 판단하는 구조를 가진다. 모델의 핵심 부분인 특징을 추출하는 부분은 ResNet-18의 아키텍처를 기반으로 하며 수식(1)에 표기한 바와 같이 잔차 학습 개념을 도입하였다.<sup>[17]</sup> 검출 이미지의 학습을 위해서 소프트맥스 함수를 통해 각 클래스에 속할 확률로 변환된다. K개의 클래스가 있을 때, 수식 (2)을 통해 j번째 클래스 확률을 구할 수 있다.

$$y = \sigma(F(x, W_i) + x) \tag{1}$$

$$\hat{y}_j = \sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \tag{2}$$

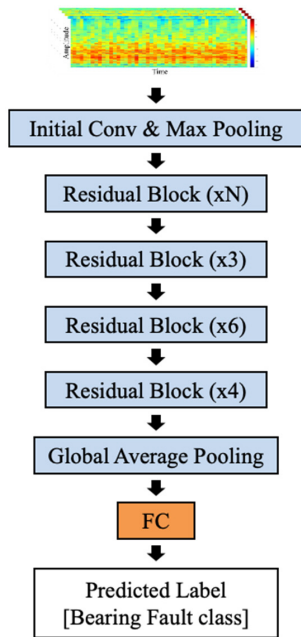


Fig. 7. Proposed 2D CNN architecture

$$L(y, \hat{y}) = - \sum_{i=1}^K y_i \log(\hat{y}_i) \tag{3}$$

예측된 확률과 실제 정답 라벨 사이의 차이를 측정하기 위하여 수식 (3)에 표기된 교차 엔트로피 손실 함수를 사용한다.<sup>[18]</sup>

Fig. 8은 본 연구에서 사용된 검증 과정에 대한 구조를 나타냈다. 각각의 베어링에서 수집한 데이터에서 1개 데이터는 학습, 검증 데이터로 분할하고 1개 데이터는 시험 데이터로 분류하였다.

전체 데이터에서 최종 검증을 위한 시험 데이터를 학습 데이터와 분할하고 하이퍼 파라미터 최적화를 위해 학습 데이터를 균일한 크기로 10등분 하였다. 이후 그리드 서치(Grid search)를 이용한 K-fold 교차 검증으로 하이퍼 파라미터 최적화를 수행하고, 이를 학습 데이터로 사용하여 학습에 사용되지 않은 시험 데이터를 이용한 결함 검출 모델의 성능을 평가할 수 있는 구조로 구성되었다. Table 3은 모델별 적용 매개변수와 그리드 서치 목록으로 그리드 서

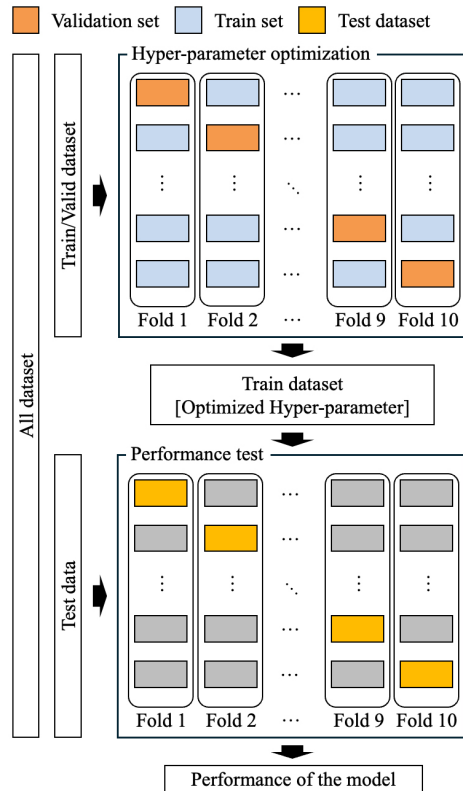


Fig. 8. Schematic of cross validation

Table 3. Grid search list for Hyper-parameter optimization of each model

Model	Parameter	List of grid search
SVM	kernel function	Linear*, RBF
	box constraint	0.1*, 1, 10
	kernel scale	0.1, 1*, 10
KNN	number of neighbors	1, 3, 5, 7*, 9
	distance	euclidian, cityblock*, cosine
1D CNN	learning rate	1e-3, 5e-3*, 1e-4
	minimum batch size	16, 32, 64*
	maximum epoch	1, 5, 10*
2D CNN	learning rate	1e-3*, 5e-3, 1e-4
	minimum batch size	16, 32*, 64
	maximum epoch	1, 5*, 10

치를 통하여 최적화된 하이퍼 파라미터의 값은 별(\*) 표시하였다.

### 3.2 결함 검출 모델의 성과 지표

베어링 결함 검출 모델은 정확도(Accuracy), 정밀도(Precision), 재현도(Recall), F1\_score 4가지 지표를 이용하여 평가하였다.<sup>[19]</sup> 각 평가 지표는 수식 (4-7)에 표기하였으며, 각 식에 표기된 True Positive(TP)는 True로 라벨된 데이터를 분류 모델에서 True로 판단한 경우, True Negative(TN)는 True로 라벨된 데이터를 분류 모델에서 False로 판단한 경우, False Positive(FP) False로 라벨된 데이터를 분류 모델에서 True로 판단한 경우, False Negative(FN)은 False로 라벨된 데이터를 False라고 판단한 경우를 뜻한다. 정확도는 전체 데이터 중 모델이 바르게 분류한 비율, 정밀도는 모델이 정상으로 분류한 샘플 중 실제 정상 데이터의 비율, 재현도는 실제 정상 데이터 중에서 바르게 분류한 비율을 뜻한다. F1\_score는 정밀도와 재현도의 성능을 동시에 고려하기 위한 지표로 0과 1 사이의 값으로 나타내며 1에 가까울수록 분류 성능의 우수함을 의미한다.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% \quad (4)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (5)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (6)$$

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

## 4. 모델 결과 비교

본 연구에서는 베어링 결함 검출 모델의 신뢰성을 확보하기 위해 제안하는 베어링 결함 검출 모델인 2D CNN과 3가지 다른 검출 모델(SVM, KNN, 1D CNN)의 성능을 비교하였다. 앞서 기술한 데이터 구축 방법에 따라 각 모델은 최적의 하이퍼 파라미터를 선정하고 학습된 모델을 테스트 세트로 평가하였다.

Fig. 9와 Table 4에 따르면 HOG 알고리즘을 통해 추출된 특징을 기반으로 학습하는 SVM, KNN 모델은 각각 79.43%, 65.37%의 정확도를 기록하였으며, 모두 롤러 단일 결함과 외륜-롤러 복합 결함을 분류하지 못하는 오탐 현상이 발생하며 저조한 성능이 나타났다. 1D CNN 모델은 50.78%라는 정확도를 기록하며 정상 데이터의 대부분을 외륜 단일 결함으로 분류하는 과탐 현상, 롤러 단일 결함과 외륜-롤러 복합 결함을 분류하지 못 하는 오탐 현상을 보였다.

그에 반해 2D CNN 모델은 92.96%의 정확도와 0.9294의 높은 F1 score를 달성하며 앞선 세 모델에 비해 우수한 성능을 보였다. 일부 롤러 단일 결함과 외륜-롤러 복합 결함 사이의 오탐 현상이 발생하는 한계가 있었으나, 정상 데이터에 대해 과탐, 미탐 현상은 하나도 발생하지 않았다. 이는 제안한 2D CNN 모델이 베어링의 정상 데이터의 특징을 명확하게 구분했음을 의미한다.

각 모델의 정량적 성능을 분석하여 고찰한 결과는 다음과 같다. 머신러닝 모델인 SVM, KNN 모델은 특징 추출 알고리즘인 HOG 알고리즘이 이미지의 지역적 기울기 정보를 1차원 벡터화하는 과정에서 스펙트로그램의 2차원 정보를 상실했기 때문에 보인다. 롤러 단일 결함과 외륜-롤러 복합 결함은 롤러 손상이라는 공통된 충격원을 공유하며 유사한 주요 특징을 갖는데, 1차원으로 벡터화한 공간에서는 두 클래스 사이에서 외륜 결함의 추가적인 차이를

Real class	Normal	284	4		
	oFault		254	12	22
	rFault		15	115	158
	orFault		4	22	262
	Normal	oFault Predicted class			
			rFault	orFault	

(a) Results of SVM

Real class	Normal	260	28		
	oFault	6	176	51	55
	rFault		15	91	182
	orFault		27	35	226
	Normal	oFault Predicted class			
			rFault	orFault	

(b) Results of KNN

Real class	Normal	146	140		
	oFault		171	40	77
	rFault		36	35	217
	orFault			56	232
	Normal	oFault Predicted class			
			rFault	orFault	

(c) Results of 1D CNN

Real class	Normal	288			
	oFault		252	26	10
	rFault			262	26
	orFault		16	3	269
	Normal	oFault Predicted class			
			rFault	orFault	

(d) Results of 2D CNN

Fig. 9. Confusion matrix

Table 4. Comparison along the classification models

Model	Accuracy	Precision	Recall	F1_score
SVM	79.43	82.16	79.43	0.7837
KNN	65.37	67.45	65.34	0.6464
1D CNN	50.78	55.16	50.80	0.4867
2D CNN	92.96	93.19	92.97	0.9294

명확하게 구분하지 못해 중첩된 결합 신호의 패턴을 파악하지 못한 것이 낮은 성능의 원인으로 보인다.

반면, 진동 시계열 신호를 직접 입력으로 사용하여 자동 특징 추출을 수행하는 1D CNN의 경우는 앞선 머신러닝 모델과는 다른 유형의 한계를 보였는데, 이는 주파수 도메인 정보의 부재가 원인으로 보인다. 1D CNN 모델은 신호의 시간적 흐름과 진폭의 변화 추이를 학습하기 때문에, 초기 결합 신호가 갖는 미세한 주기적 충격이 배경 노이즈와 시간 파형 상에서 유사하게 나타날 경우 이를 명확하게 분류하지 못한다. 결과적으로, 구현한 결합의 크기가 매우 작았기 때문에 진폭 변화에만 의존하는 1D CNN은 결합 신호를 명확하게 식별하는 데 실패하였다.

마지막으로 본 연구에서 제안한 2D CNN 모델은 앞선 3가지 모델에서 보인 한계를 극복하고 우수한 성능을 입증하였는데, 이는 STFT 스펙트로그램을 2차원 이미지로 처리하는 공간적 특징 학습 방식에 있다. 1차원 모델의 한계인 노이즈와 결합 신호의 구분 문제를 2D CNN은 이미지상의 패턴 인식을 통해 해결하여 높은 신뢰성을 확보하였다. 비록 롤러 단일 결합과 외륜-롤러 복합 결합에서 일부 분류하지 못하는 경우가 있었으나, 이는 물리적 신호의 중첩으로 인해 외륜 결합 성분이 강한 롤러 결합 신호에 마스킹되는 현상 때문으로 데이터 자체의 한계라고 볼 수 있다. 그럼에도 불구하고 제안한 모델이 다른 모델보다 높은 성능을 보이는 것은 중첩된 신호 속에서도 미세한 픽셀 단위의 패턴 차이를 감지할 수 있는 공간 필터의 우수성을 입증하는 결과이다.

앞선 결과를 종합하면 베어링 결합 검출에서 모델의 성능을 결정하는 인자는 입력 데이터가 내포한 시간-주파수 영역의 관계를 손실 없이 보존하고 학습하는 것에 있다. 스펙트로그램 이미지의 공간 구조를 벡터화하는 과정에서 위상 정보를 잃은 SVM, KNN이나 시계열 신호를 통해 시간 정보만 학습하는 1D CNN과 다르게 2D CNN은 베어링의 치수나 결합 주파수와 같은 사전 정보 없이 2차원 정보인 스펙트로그램 이미지를 활용하여 결합 검출 모델의 강건성, 복합 결합 분해 능력을 확보할 수 있었다. 따라서 베어링의 치수와 같은 사전 정보가 없더라도 복잡하고 가변적인 진동 신호를 다루는 정밀 진단 시스템 구축을 위해서 비교한 3가지 다른 모델보다도 2차원 시간-주파수 이미지 분석에 특화된 2D CNN 기반의 접근 방식이 필수적으로 요구된다.

## 5. 결론

본 연구에서는 풍력발전기 운용 현장에서 베어링의 상세 제원이나 결함 상태와 같은 정보를 사전에 확보하기 어렵다는 제약을 극복하고자 베어링의 정보 없이도 결함을 강건하게 검출할 수 있는 딥러닝 모델을 개발하였다. 이를 검증하기 위해 풍력발전기의 다양한 운전 조건과 결함 상태를 모사한 실험 데이터를 구축하였으며, 제안하는 2D CNN 모델과 기존의 3가지 분류 모델(SVM, KNN, 1D CNN)의 성능을 비교·분석하였다.

실험 결과 1D CNN은 50.78%의 저조한 정확도를 보이며 배경 노이즈에 묻힌 초기 결함의 미세한 진폭 변화를 감지하는 데 실패했고, SVM, KNN 또한 1차원 특징 벡터화 과정에서 정보 손실로 인해 복합 결함 패턴을 명확하게 구분하지 못하는 한계를 드러냈다. 반면, 제안하는 2D CNN 모델은 92.96%의 정확도와 0.9294의 F1 score를 기록하며 비교 모델 대비 압도적인 성능을 입증하였다. 이러한 결과는 2D CNN이 STFT 스펙트로그램의 시간-주파수 영역에 나타난 고유한 공간적 특징을 스스로가 학습하여 베어링의 기구학적 정보나 물리적 파라미터가 부재한 상황에서도 신호의 이미지 패턴 학습만으로 노이즈와 결함을 효과적으로 식별할 수 있음을 시사한다.

결론적으로 본 연구를 통해 단순 시계열 분석이나 수동 특징 추출 방식보다 2D CNN 기반의 공간적 특징 추출 기법이 정보가 부족한 현장 데이터 환경에서 결함 검출에 유리함을 확인하였다. 그러나 본 연구는 풍력발전기의 핵심 부품 중 베어링의 결함 검출에만 집중하였고 기어나 축 등 구동계의 다른 구성 요소에서 발생할 수 있는 결함 가능성은 포괄적으로 고려하지 않았다는 한계가 있으며, 이를 실제 복합 시스템에 적용하기엔 한계가 있다.

따라서 향후 연구에서는 이러한 한계를 극복하고 모델의 실용성을 증대시키기 위해, 센서의 측정 위치가 달라지거나 베어링의 종류가 변경되어도 일관된 성능을 유지할 수 있는 도메인 일반화 모델을 개발할 예정이다. 또한, 적은 양의 데이터로도 다른 부품의 결함을 탐지할 수 있는 전이 학습 기반의 고장 진단 연구를 진행할 계획이다.

## 감사의 글

본 연구는 한국에너지기술연구원의 기본사업(C6-2410)을 재원으로 수행한 연구과제의 결과입니다.

## References

- [1] Global Wind Energy Council, 2025, "Global Wind Report 2025", Global Wind Energy Council (GWEC), <https://26973329.fs1.hubspotusercontent-eu1.net/hubfs/26973329/2.%20Reports/Global%20Wind%20Report/GWEC%20Global%20Wind%20Report%202025.pdf>.
- [2] Blumenfeld, M., Cooperman, A., Zuckerman, G., Prilliman, M., Keller, J., and Sheng, S., 2024, "Wind Turbine Maintenance Costs: Assessing the Potential of Gear Oil Improvements", National Renewable Energy Laboratory (NREL), Golden, CO, <https://docs.nrel.gov/docs/fy25osti/90268.pdf>.
- [3] Gielen, D., 2012, "Renewable energy technologies: cost analysis series", International Renewable Energy Agency (IRENA), [https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2012/RE\\_Technologies\\_Cost\\_Analysis-BIOMASS.pdf](https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2012/RE_Technologies_Cost_Analysis-BIOMASS.pdf).
- [4] Watanabe, F., and Uchida, T., 2015, "Micro-Siting of Wind Turbine in Complex Terrain: Simplified Fatigue Life Prediction of Main Bearing in Direct Drive Wind Turbines", *Wind Eng.*, **39**(4), 349-368.
- [5] Liu, H., Wang, Y., Zeng, T., Wang, H., Chan, S.C., and Ran, L., 2024, "Wind turbine generator failure analysis and fault diagnosis: A review", *IET Renew. Power Gener.*, **18**(15), 3127-3148.
- [6] Pulikollu, R., Haus, L., Mclaughlin, J., and Sheng, S., 2024, "Wind Turbine Main Bearing Reliability Analysis, Operatinos, and Maintenance Considerations: Electric Power Research Institute (EPRI)", National Renewable Energy Laboratory (NREL), <https://www.epri.com/research/products/000000003002029874>.
- [7] Yadav, O.P., and Pahuja, G.L., 2020, "Bearing Health Assessment Using Time Domain Analysis of Vibration signal", *Int. J. Image Graph. Signal Process. (IJIGSP)*, **12**(3), 27-40.

- [8] Zhou, L., Duan, F., Mba, D., Corsar, M., Greaves, M., Sampath, S., and Elasha, F., 2016, "Helicopter gearbox bearing fault detection using separation techniques and envelope analysis", Proc. Prognostics and system Health Management Conference (PHM-Chengdu), Chengdu, China, 1-5, <https://doi.org/10.1109/PHM.2016.7819888>.
- [9] Courrech, J., and Gaudel, M., 2001, "Envelope analysis-the Key to rolling-element bearing diagnosis", Brüel & Kjær Application Notes, <https://www.scribd.com/document/507328216/Envelope-Analysis-the-key-to-rolling-element-bearing-diagnosis>.
- [10] Samanta, B., Al-Balushi, K.R., and Al-Araimi, S.A., 2003, "Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection", Eng. Appl. Artif. Intell., **16**(7-8), 657-665.
- [11] Shao, H., Jiang, H., Lin, Y., and Li, X., 2018, "A novel methods for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders", Mech. Syst. Signal Process., **102**, 278-297.
- [12] Wang, S., Sun, W., Liu, H., Bao, S., Wang, Y., and Zhao, X., 2025, "Research on Wind Turbine Main Shaft Bearing Fault Diagnosis Method Based on Unity 3D and Transfer Learning", Appl. Sci., **15**(4). 2003.
- [13] Clifton, A., Barber, S., Bray, A., Enevoldsen, P., Fields, J., Sempreviva, A.M., Williams, L., Quick, J., Purdue, M., Totaro, P., *et al.*, 2023, "Grand challenges in the digitalisation of wind energy", Wind Energ. Science, **8**, 947-974.
- [14] Hart, E., Clarke, B., Nicholas, G., Amiri, A.K., Stirling, J., Carroll, J., Dwyer-Joyce, R., McDonald, A., and Long, H., 2020, "A review of wind turbine main bearings: design, operation, modelling, damage mechanisms and fault detection", Wind Energy Science, **5**(1), 105-124.
- [15] Krishnan, S., 2023, "A Comparative Review of the Lubrication of Bearings in Wind Turbines and Spacecraft to Address Wind Turbine Bearing Failures", Tribology in Industry, **45**(1), 257-271.
- [16] SKF, Tapered roller bearings, Accessed 10 December 2025, <https://www.skf.com/uk/products/rolling-bearings/roller-bearings/tapered-roller-bearings/single-row-tapered-roller-bearings/productid-30308%2FVA983>.
- [17] He, K., Zhang, X., Ren, S., and Sun, J., 2016, "Deep Residual Learning for Image Recognition", Proc. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 770-778.
- [18] LeCun Yann, Bottou Léon, Bengio Yoshua, and Haffner Patrick, 1998, "Gradient-based learning applied to document recognition", Proc. IEEE, **86**(11), 2278-2324, [http://vision.stanford.edu/cs598\\_spring07/papers/Lecun98.pdf](http://vision.stanford.edu/cs598_spring07/papers/Lecun98.pdf).
- [19] Li, Z., Li, Y., Sun, Q., and Qi, B., 2022, "Bearing Fault Diagnosis Method Based on Convolutional Neural Network and Knowledge Graph", Entropy, **24**(11), 1589.