

Memory-Based Anomaly Segmentation for Fire Detection in Wind Turbine Nacelle Monitoring Systems

DoHyeong Kim*, SeungWoo Son**, SunHo Park***

*Researcher, KEPCO Research Institute, Naju, Korea

**Senior Researcher, KEPCO Research Institute, Naju, Korea

***Principal Researcher, KEPCO Research Institute, Naju, Korea

[Abstract]

Wind turbine nacelles are often inaccessible, making real-time fire detection crucial to prevent severe damage and downtime. However, monitoring is hindered by the scarcity of anomaly data compared to normal data. To address this, this study proposes a PatchCore-based one-class memory modeling framework using only normal data to approximate complex feature distributions via non-parametric nearest-neighbor modeling. The model was trained exclusively on normal nacelle data and compared against OCSVM, LOF, and PaDiM. Experimental results show PatchCore's superiority achieving an image-level AUROC of 0.96 and a pixel-level AUROC of 0.83. These results demonstrate that memory-based modeling effectively represents complex normal feature spaces, providing robust anomaly detection performance for wind turbine environments.

▶ **Key words:** Wind turbine, Anomaly detection, Fire detection, Segmentation, Deep learning

[요 약]

풍력 터빈 나셀은 접근이 어려운 환경에 설치되어 있어, 설비 손상과 가동 중단 방지를 위한 실시간 화재 탐지가 필수적이다. 그러나 정상 데이터에 비해 이상 데이터가 극히 부족하여 효율적인 모니터링에는 한계가 있다. 이를 해결하기 위해 본 연구에서는 정상 데이터만을 활용하는 PatchCore 기반 one-class 메모리 모델링 프레임워크를 제안한다. 이 방식은 비매개변수적 최근접 이웃 모델링을 통해 복잡한 특징 분포를 효과적으로 근사한다.

나셀 내부의 정상 데이터로만 학습된 제안 모델을 OCSVM, LOF, PaDiM과 비교 평가한 결과, PatchCore는 이미지 수준 AUROC 0.96, 픽셀 수준 AUROC 0.83을 달성하며 가장 우수한 성능을 보였다. 실험 결과는 메모리 기반 모델이 복잡한 정상 특징 공간을 정교하게 표현할 수 있으며, 풍력 터빈 환경에서 강건한 이상 탐지 성능을 제공함을 입증한다.

▶ **주제어:** 풍력터빈, 이상 탐지, 화재 감시, 분할 기법, 딥러닝

• First Author: DoHyeong Kim, Co-Author: SeungWoo Son, Corresponding Author: SunHo Park

*DoHyeong Kim (kdh97@kepco.co.kr), KEPCO Research Institute

**SeungWoo Son (swson.20@kepco.co.kr), KEPCO Research Institute

***SunHo Park (sunho.park@kepco.co.kr), KEPCO Research Institute

• Received: 2026. 03. 10, Revised: 2026. 04. 01, Accepted: 2026. 04. 10.

I. Introduction

최근 전 세계적으로 탄소중립 및 친환경 에너지 전환 정책이 가속화되면서, 풍력에너지는 핵심적인 재생에너지 자원으로 자리 잡고 있다. 이에 따라 대형 풍력발전 단지는 해안, 산지, 해상과 같이 접근이 어려운 지역에 대규모로 구축되고 있다. 이러한 설치 환경은 유지보수 인력의 접근성을 제한하고, 기상 조건과 작업 안전성 문제를 동반하여 설비 운영의 안정성을 위협한다. 특히 해상 및 산악 지역에 위치한 풍력터빈의 경우, 고장 발생 시 즉각적인 대응이 어렵기 때문에 무인 기반의 상시 감시 체계 구축이 필요하다.

풍력발전기는 장기간 연속 운전 과정에서 다양한 형태의 결함이 나타나며, 그중 화재는 가장 치명적인 사고 유형 중 하나로 보고된다. 2000년부터 2023년까지 전 세계적으로 보고된 3,287건의 풍력 터빈 사고 중 약 14%가 화재 사고로 분류되며[1], 이는 기어박스, 메인베어링, 전기 패널과 같은 핵심 구성요소에 영구적인 손상을 초래하고 심각한 경우 전체 터빈 상실로 이어질 수 있다. 이러한 위험을 줄이기 위해 온도, 진동, 전기 신호 등을 활용한 센서 기반 상태감시 시스템을 적용했지만, 실제 운전 환경에서는 풍속 변화, 부하 변동, 온-습도 변화와 같은 외란이 지속적으로 존재하며, 이로 인해 센서 기반 경보 시스템은 오탐지와 이상 미검출 문제가 존재한다. 또한 센서 신호는 공간적 위치 정보를 직접 제공하지 못하므로, 나셀 내부의 어느 지점에서 이상이 발생했는지를 직관적으로 파악하기 어렵다는 구조적 한계 또한 존재한다.

이러한 한계를 보완하기 위해 영상 기반 이상 탐지가 주목받고 있다. 카메라 기반 감시는 비접촉 방식으로 넓은 영역을 동시에 관찰할 수 있으며, 화재·연기·과열과 같은 시각적 이상 징후를 공간적으로 확인할 수 있다는 장점이 있다. 특히 딥러닝 기반 특징 추출 기법의 발전은 산업 설비 영상에서 미세한 이상 패턴을 학습할 수 있는 가능성을 제시한다.

그러나 실제 풍력터빈 나셀 내부 환경에서 수집된 영상에는 심각한 데이터 불균형 문제가 존재한다. 화재와 같은 고위험 이상 상황은 발생 빈도가 낮고, 안전상의 이유로 의도적 재현이 어렵기 때문에 대부분의 학습 데이터는 정상 상태로 구성된다. 따라서 다수의 결함 데이터를 요구하는 지도학습 기반 접근은 제약을 가진다.

따라서 본 문제는 단순한 이상 탐지 문제가 아니라, (1) 정상 데이터만으로 학습 가능한 one-class 기반 구조를 요구하며, (2) 이상 영역을 공간적으로 국소화할 수 있는

세그멘테이션 형태의 출력이 가능해야 하는 복합적 문제로 정의된다. 이에 본 연구에서는 풍력터빈 나셀 내부에서 수집된 실제 영상 데이터를 기반으로, 정상 데이터 중심의 one-class 이상 탐지 구조를 채택하고, ImageNet 사전학습 모델을 활용하여 패치 단위 특징 임베딩을 활용하여 국소적 이상을 정량화하고, 이를 픽셀 단위 anomaly map으로 확장함으로써 화재 관련 이상을 공간적으로 시각화할 수 있는 프레임워크를 제안한다. 이를 통해 본 연구는 실제 나셀 환경에서 수집된 데이터를 기반으로 실증적 one-class 이상 탐지 프레임워크를 제안한다.

본 논문의 구성은 다음과 같다. II장에서는 풍력터빈 나셀 내부 화재 감시 및 영상 기반 이상 탐지와 관련된 기존 연구를 정리한다. III장에서는 정상 데이터 기반 메모리 모델링을 활용한 PatchCore 기반 이상 탐지 기법과 RGB 및 열화상 다중 영상 스트림을 결합한 방법론을 상세히 설명한다. IV장에서는 FLIR Hadron 640R 복합 센서를 이용한 데이터 수집 과정과 다양한 촬영 조건을 포함한 실험 환경을 기술한다. V장에서는 제안 방법의 성능을 기존 기법들과 비교하여 정량적 및 정성적으로 분석한다. 마지막으로 VI장에서는 본 연구의 주요 결과를 요약한다.

II. Related works

1. Research on Time-series Data-Based Anomaly Detection for Wind Turbines

풍력터빈 상태감시는 SCADA 시계열 데이터와 각종 센서 신호를 중심으로 발전해 왔다. 대표적으로, SCADA 데이터의 다변량 시계열을 입력으로 하여 기어박스 온도, 압력, 발전출력 등의 변화를 학습하고 이상을 탐지하는 방법들이 제안되었다. Liu et al.은 풍력터빈 SCADA 변수들을 군집화한 뒤, 군집 내·외 상관관계를 이용해 이상 상태를 탐지하는 방법을 제안하여, 일반적인 상태 이상과 일부 기계 결함을 조기에 검출할 수 있음을 보였다[2]. Miele et al.은 수평축 풍력터빈을 대상으로, SCADA 데이터 기반의 비지도 딥러닝 이상 탐지 프레임워크를 제안하여, 정상 운전 패턴으로부터의 편차를 자동으로 모델링하는 접근을 제시하였다[3]. 최근에는 해상 풍력터빈을 대상으로, SCADA 시계열 데이터와 Temporal Convolutional Network(TCN)-Efficient Channel Attention(ECA)을 결합하여 조기 화재 경보 모델을 설계한 연구도 보고되었다. 이 연구는 다변량 시계열의 시·공간 상관관계를 고려한 모델링을 통해 화재 관련 이상 징후를 조기에 탐지할 수 있음

을 보인다[4]. 또한, 기어박스·베어링 등 회전체 부품을 대상으로 한 진동 센서 기반 상태감시 및 결함 진단 연구 역시 풍력 분야에서 널리 수행되어 왔다. Salameh et al.의 리뷰는 블레이드, 베어링, 기어박스, 발전기 등에 대한 진동 신호 분석 기법들을 정리하면서, 각 구성 요소별 대표적인 고장 모드와 센서 기반 감시 전략을 체계적으로 제시한다[5]. 그러나 실제 현장 사례에서는, 표준적인 센서 진단 기법이 기어박스의 중대한 결함을 제때 검출하지 못해 장기간의 다운타임으로 이어진 사례도 보고되고 있으며, 이를 보완하기 위한 데이터 처리·융합 알고리즘이 추가로 제안되고 있다[6]. 이러한 연구들은 SCADA 및 센서 기반 상태감시가 풍력터빈 결함·화재 위험을 줄이는 데 유효한 도구임을 보여주지만, 센서·시계열 데이터는 공간적 정보(spatial context)가 제한적이어서, 나셀 내부의 어느 위치에서 이상이 발생했는지 직관적으로 파악하기 어렵고, 센서 신호는 바람, 부하, 온도 등 외란에 민감하여, 임계값 기반 경보 설정 시 오탐지·이상 미검출 문제가 발생한다. 이러한 이유로, 센서 기반 감시만으로는 나셀 내부 화재와 같은 시각적 이상을 정밀하게 감시하는데 한계가 존재한다.

2. Research on Image-Based Anomaly Detection for Wind Turbines

센서 및 시계열 기반 감시 방식의 한계를 보완하기 위해, 최근에는 영상 데이터를 활용한 풍력터빈 화재 및 결함 감지 연구가 점차 확대되고 있다. 특히 나셀 내부에서 발생하는 화재 및 연기와 같은 시각적 이상 현상을 딥러닝 기반 영상 분석으로 탐지하려는 시도가 이루어지고 있다. Do et al.은 풍력터빈 나셀 내부 화재감지를 위해 계층적 심층신경망 기반의 영상감시 프레임워크를 제안하였다. 해당 연구에서는 화재 및 연기 이미지를 이용한 지도학습 기반 분류 모델을 먼저 적용하여 오탐지를 감소시키고, 이후 객체탐지 네트워크를 통해 화재 발생영역을 국소화하였다. 실제 나셀환경을 모사한 영상 데이터셋을 구축하여 성능을 검증함으로써, 영상기반 화재감시의 가능성을 제시하였다[7]. 또한 Lee et al.은 풍력터빈 나셀을 대상으로 RGB 카메라, 열화상 카메라, 3D LiDAR를 결합한 멀티모달 화재 감지 및 소화 시스템을 제안하였다. 이 연구에서는 딥러닝 기반 분류 및 탐지 모델을 활용하여 화재 및 과열 영역을 영상 상에서 식별하고, 센서 융합을 통해 화재 위치의 신뢰성을 향상시키고자 하였다[8]. 그러나 이와 같은 지도학습기반 접근법은 학습에 사용된 화재 및 연기패턴에 강하게 의존하며, 학습되지 않은 형태의 이상 상황이나 환경 변화에 대해서는 일반화 성능이 제한되는 한계를 가진

다. 나셀 내부 화재와 같은 고위험 환경에서는 영상 데이터 수집 및 정밀한 어노테이션 자체가 높은 비용과 위험을 수반하므로, 지도학습 기반 영상 이상 탐지 기법의 실질적 적용에는 한계가 존재한다.

한편, 실제 결함 및 화재 영상 데이터의 부족을 보완하기 위해 합성 데이터(synthetic data)를 생성하여 학습에 활용하는 연구도 보고되고 있다. 예를 들어, 풍력터빈 블레이드 결함 검출을 목적으로 합성 열 화상 데이터를 생성하여 데이터 불균형 문제를 완화하고, 실제 데이터와의 분포 차이를 줄이기 위한 변환 기법을 적용한 연구가 제안되었다[9]. 또한 GAN 기반 생성 모델을 활용하여 소량의 실제 결함 이미지를 바탕으로 다양한 결함 영상을 생성함으로써 학습 데이터셋을 확장하는 방법도 연구되었다[10]. 이와 같은 합성 데이터 기반 접근은 결함 클래스 간 데이터 불균형을 완화하는 데 기여하지만 실제 나셀 내부의 조명 조건, 노이즈, 카메라 시점 변화, 오염 상태 등을 완벽히 반영하기 어렵기 때문에, 실제 데이터와의 도메인 차이가 남아 실환경 적용 시 일반화 성능에 제약이 발생한다.

3. Research on Semi-Supervised & Unsupervised Anomaly Detection for Wind Turbines

앞서 언급한 데이터 불균형 문제를 고려하여, 풍력터빈 이상 탐지 분야에서도 반지도(semi supervised) 및 비지도(unsupervised) 기반 이상 탐지 연구가 점차 확대되고 있다. 이러한 접근법은 정상 상태 데이터만을 활용하여 이상 패턴을 자동으로 학습하고, 학습된 정상 분포로부터 벗어나는 영상을 이상으로 판단하고자 한다.

비록 풍력터빈 나셀 화재를 직접 대상으로 한 반지도·비지도 영상 이상 탐지 연구 사례는 아직 제한적이지만 대표적으로 드론영상 기반 풍력터빈 블레이드 이상 탐지 연구가 있으며, Wang et al.은 ImageNet 사전학습 네트워크에서 추출한 deep feature를 입력으로 사용하는 one-class SVM 기반 비지도 이상 탐지 방법을 제안하였다. 이 연구는 정상 블레이드 패턴을 중심으로 특징 공간을 형성한 뒤, 이와 유사하지 않은 패치를 이상으로 분류하여 소량의 이상 데이터 환경에서도 결함 후보를 자동으로 제시하였다. 이러한 비지도 방법은 레이블이 제한된 상황에서도 anomaly score 기반 후보 영역을 제공할 수 있음을 보여준다 [11]. 또한 산업설비 영상 이상 탐지 프레임워크를 제시하는 연구에서는, 정상영상만으로 학습된 모델이 다양한 구성요소의 이상을 열지도(heatmap) 또는 anomaly map 형태로 출력할 수 있는 비지도 구조가 제안되었다. 이러한 영상 기반 anomaly detection 프레임워크는 풍력 설비의 이상 탐지

에도 개념적으로 확장 가능하다[12].

그러나 반지도·비지도 기반 접근에도 여전히 한계가 존재한다. 많은 방법들이 이미지 단위 또는 patch 단위의 anomaly score만을 제공할 뿐, 구체적인 이상 영역을 픽셀 단위 세그멘테이션 형태로 명확히 제시하지 못한다는 점이다. 이러한 경우 실제 실증 및 운영 단계에서는 모델이 제시한 anomaly score 영역을 사람이 추가로 검증해야 하므로, 인력 및 시간 소모가 발생한다. 이러한 한계는 풍력터빈 나셀 내부 화재와 같은 국부적이고 고위험인 이상 현상을 실질적으로 감시하기 위해서는, 단순 비지도 이상 점수 산출을 넘어 픽셀 단위 이상 세그멘테이션 프레임워크가 필요함을 시사한다.

III. Methodology

본 연구는 풍력터빈 나셀 내부 영상에서 정상 데이터만을 활용하여 이상을 탐지하는 one-class 기반 PatchCore 프레임워크를 제안한다. PatchCore는 정상 패치 임베딩을 직접 메모리 뱅크에 저장하고 최근접 거리 기반으로 이상을 판단하는 구조를 가지므로, 별도의 결함 데이터 없이 정상 분포를 비모수적(non-parametric) 방식으로 근사할 수 있다. 이는 화재와 같은 고위험 이상 데이터를 충분히 확보하기 어려운 산업 환경에서 구조적으로 유리하다. 또한 PatchCore는 정상 feature 분포를 전역적인 단일 통계 모델로 가정하지 않고, 다수의 정상 패치 임베딩 집합으로 표현한다. 나셀 내부 영상은 반복적인 기계 구조, 금속 표면 반사, 부분적 음영 등으로 인해 feature 공간이 다봉(multi-modal) 및 비선형 구조를 형성한다. 이러한 환경에서 분포 기반 방법(PaDiM)이나 경계 기반 방법(OCSVM)은 정상 분포를 단일 확률 모델 또는 결정 경계로 근사하기 때문에 표현 한계가 발생할 수 있다. 반면 PatchCore는 최근접 거리 계산을 통해 정상 분포의 복잡한 형상을 직접 근사하므로, 비선형 구조와 다봉 분포에 보다 유연하게 대응할 수 있다.

이와 같은 특성으로 인해 PatchCore는 정상 데이터 중심 학습, 복잡한 정상 분포 모델링이라는 본 연구의 두 가지 기술적 요구 조건을 동시에 충족하는 적합한 이상 탐지 구조로 선택되었다. 또한 본 연구에서는 실제 산업 현장에서 활용 가능성이 높은 대표적 이상 탐지 기법들을 비교 대상으로 선정하였다. 이에 따라, 산업 환경에서 주로 사용되고 있는 OCSVM, LOF, PaDiM과 같은 안정성을 갖춘 대표적인 이상 탐지 기법들을 비교 대상으로 선정하였다.

1. Feature Extraction

입력 영상 $I \in R^{H \times W \times 3}$ 는 backbone 네트워크 $\phi(\cdot)$ 를 통해 공간적 feature map으로 변환된다:

$$F = \phi(I), F \in R^{H' \times W' \times C}$$

여기서 H', W' 는 다운샘플링된 공간 해상도이며, C 는 채널 수이다. 각 위치 (u, v) 에서의 패치 임베딩 벡터를 다음과 같이 정의한다:

$$f_{u,v} = F(u, v), f_{u,v} \in R^C$$

이를 통해 전체 패치 집합은 다음으로 표현된다.

$$F = f_{i=1}^N, N = H' \times W'$$

2. Memory Bank Construction (PatchCore)

정상 데이터로부터 추출된 패치 임베딩 집합을 $F_n = \{f_i\}_{i=1}^M$ 이라 할 때, 모든 벡터를 저장하는 대신 coresetsampling을 통해 대표 집합 M 을 구성한다:

$$M \subset F_n, |M| = m, m \ll |F_n|$$

Greedy k-center 방식으로 다음 목적을 최소화한다:

$$\min_M \max_{f \in F_n} \min_{m \in M} \|f - m\|_2$$

이를 통해 정상 분포를 효율적으로 근사하는 메모리 뱅크를 구성한다.

3. Patch-Level Anomaly Scoring

테스트 영상 $I(t)$ 에 대해 패치 임베딩 $f_i(t)$ 를 추출한 후, 메모리 뱅크와의 최근접 거리로 anomaly score를 계산한다:

$$s_i = \min_{m \in M} \|f_i^{(t)} - m\|_2$$

이는 정상 분포로부터의 거리 기반 편차를 의미한다. 영상 단위 이상 점수는 다음과 같이 정의된다:

$$S(I^{(t)}) = \max_i s_i$$

4. Pixel-Level Anomaly Map Generation

패치 단위 점수 s_i 를 원래 영상 해상도로 보간하여 anomaly map A 를 생성한다:

$$A(x, y) = \text{Interp}(s_i)$$

여기서 $\text{Interp}(\cdot)$ 는 bilinear interpolation 연산이다. 이후 Gaussian smoothing을 적용하여 공간적 노이즈를 완화한다:

$$A' = G_\sigma * A$$

최종적으로 adaptive threshold θ 를 적용하여 이진 마스크를 생성한다:

$$M(x,y) = \begin{cases} 1 & \text{if } A'(x,y) > \theta \\ 0 & \text{otherwise} \end{cases}$$

이를 통해 픽셀 단위 이상 세그멘테이션이 수행된다.

5. Multi-View Ensemble for Nacelle Monitoring

실제 풍력터빈 나셀 내부 감시 환경에서는 카메라 설치 위치의 제약, 통신 장애, 유지보수 과정에서의 장비 분리 등으로 인해 일부 카메라 영상이 일시적으로 수신되지 않는 상황이 발생할 수 있다. 특히 본 연구에서 사용한 나셀 감시 시스템은 내부를 서로 다른 방향에서 관측하는 다중 카메라 구조로 구성되어 있으며, 정상적인 상황에서는 총 네 개의 영상 스트림이 동시에 입력된다. 그러나 실제 운영 환경에서는 특정 카메라의 영상이 누락되거나 일부 시점에서 데이터가 수신되지 않는 경우가 존재한다.

이러한 문제를 고려하여 본 연구에서는 그림 1과 같이 각 카메라 영상에 대해 독립적인 PatchCore 기반 이상 탐지 모델을 구성하고, 최종 이상 판단 단계에서 결과를 결합하는 multi-view ensemble 구조를 적용하고, 일부 카메라 입력이 누락된 경우에는 해당 view를 ensemble 대상에서 제외하고, 사용 가능한 카메라 입력에 대해서만 최종 anomaly score를 계산하였다. 카메라 k 에 대해 입력 영상 $I(k)$ 가 주어질 때, 각 영상에 대한 anomaly score는 다음과 같이 계산된다:

$$S_k = S(I^{(k)})$$

여기서 $S(I^{(k)})$ 는 앞 절에서 정의한 k 번째 입력 영상에 대해 PatchCore 기반 영상 단위 이상 점수이다. 다중 카메라 입력이 모두 존재하는 경우, 전체 시스템의 최종 이상 점수는 다음과 같이 정의된다:

$$S_{ensemble} = \max_{k \in V} S_k$$

여기서 V 는 현재 입력이 존재하는 카메라 집합이다. 또한 일부 카메라 영상이 누락된 경우에도 동일한 식을 적용하여, 사용 가능한 영상 집합에 대해서만 ensemble score를 계산한다:

$$V = \{k | I^{(k)} \text{ available}\}$$

이를 통해 특정 카메라 영상이 일시적으로 수신되지 않는 상황에서도 시스템 전체의 이상 탐지 기능을 안정적으로 유지할 수 있다.

이와 같은 multi-view ensemble 구조는 특정 카메라 시점에서 발생하는 가림이나 조명 변화로 인한 오탐지 영향을 완화하고 여러 시점에서 관측된 이상 패턴을 통합하여 국소적인 화재 및 연기 징후와 같은 이상 현상의 탐지 신뢰도를 향상시킬 수 있다. 또한 일부 카메라 입력이 누락되더라도 시스템 전체의 감시 기능이 유지되는 fault-tolerant 구조를 제공한다. 전체 이상 탐지 모델의 구조는 그림 1에서 확인할 수 있다.

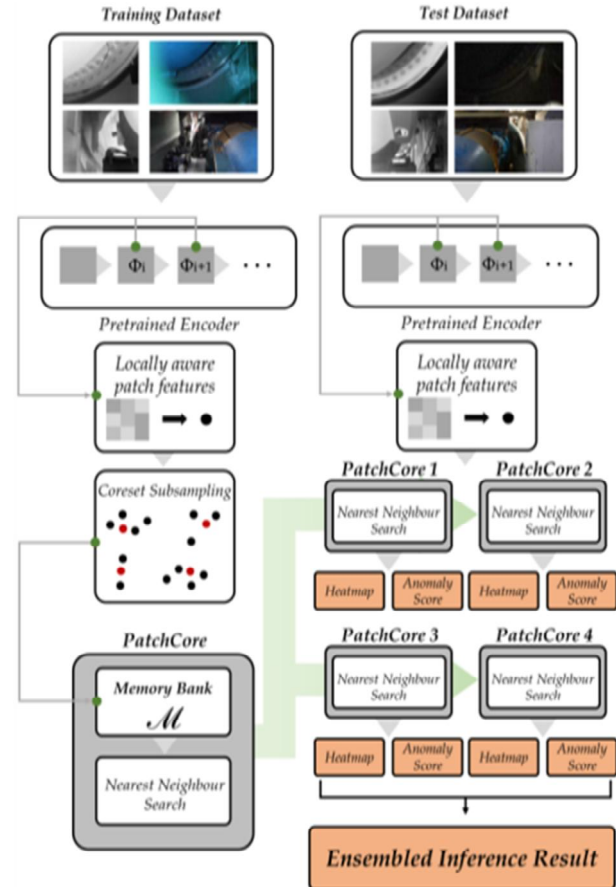


Fig. 1. Overview of Framework of the Anomaly Detection Model

6. Implementation Details

본 연구의 구현 세부 사항은 다음과 같다. 백본 네트워크는 ImageNet으로 사전학습된 ResNet50을 사용하였으며, 다중 스케일 특징을 활용하기 위해 conv3 block4와 conv4 block6 레이어의 feature map을 추출하였다. 추

출된 feature map으로부터 patch size 3, stride 1의 sliding window를 적용하여 patch embedding을 생성하였으며, 정상 데이터로부터 구성된 메모리 बैं크에 저장하였다. 메모리 효율성과 대표성 확보를 위해 k-center greedy 기반의 coresets sampling을 적용하였고, sampling 비율은 1%로 설정하였다. 이상 점수는 test patch와 메모리 बैं크 간의 최근접 이웃 거리(Euclidean distance)를 기반으로 계산하였다. 생성된 anomaly map에는 공간적 일관성을 향상시키기 위해 Gaussian smoothing($\sigma = 4$)을 적용하였다. 이미지 단위의 이상 판단은 anomaly map 내 최대값을 기준으로 수행하였다.

비교 방법인 LOF, OCSVM, PaDiM 또한 동일한 feature extractor를 기반으로 추출된 patch embedding을 입력으로 사용하였다. 각 방법의 주요 파라미터는 일반적으로 사용되는 설정을 따랐으며, LOF는 $n_neighbors = 35$, OCSVM은 Linear 커널과 $\nu = 0.05$ 로 설정하였다. PaDiM은 feature 분포를 Gaussian으로 모델링하는 방식으로 구현하였으며 채널 축소 및 통계 추정 과정은 기존 연구 설정을 기반으로 수행하였다. 또한 입력 modality로는 2대의 Hadronb 640R 카메라로부터 획득된 RGB 및 열화상 영상으로 구성된 총 4개의 영상 스트림을 사용하였다.

IV. Data Acquisition

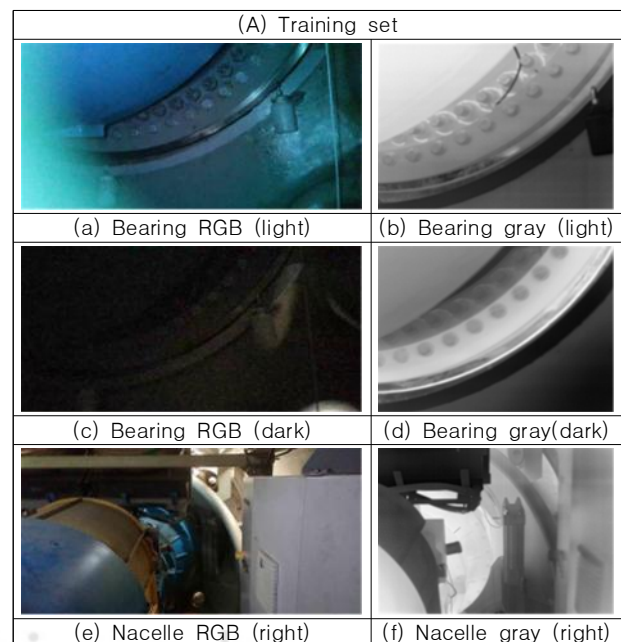
본 연구에서 사용된 영상 데이터는 실제 풍력터빈 시제기인 UNISON U113의 나셀 내부에서 수집되었다. 데이터 수집은 시제기의 운전 조건을 모사한 환경에서 수행되었으며, 화재 및 국부 과열 가능성이 높은 구성요소를 중심으로 촬영되었다. 촬영에는 산업용 복합 센서 카메라인 FLIR Hadron 640R이 사용되었으며, RGB와 열화상 영상을 동시에 수집하였다. RGB 영상은 1920×1080 해상도의 3채널로, 열화상 영상은 640×512 해상도의 1채널로 수집되었다.

Hadron 640R 카메라는 총 두 위치에 설치되었다. 첫 번째는 메인베어링 인근에 고정식으로 설치하여 베어링 및 축계 주변에서 발생하는 국부 과열 및 연기 징후를 모니터링하였다. 둘째, 기어박스 상부에 좌우 이동이 가능한 방식으로 추가 설치하여, 나셀 내부 전반을 스캔하며 데이터를 수집하였다. 최종으로 카메라 2대를 설치하여 각 카메라에서 RGB 영상과 열화상 영상이 동시에 출력되므로 총 4개의 영상 스트림을 활용하여 메인프레임, 발전기, 전

기 패널, 케이블 등 다양한 구성요소에서 발생할 수 있는 이상 상황을 포괄적으로 관찰할 수 있도록 하였다.

수집된 데이터는 정상 운전 상태에서 6개월(2025.06~2025.12)간 영상을 촬영하였다. 데이터에서는 조도 변화, 진동에 따른 흔들림, 미세한 온도 변화 등 실제 환경에서 나타나는 다양한 변동성이 포함되어 있다. 결과적으로, 본 데이터셋은 정상 데이터가 많은 불균형 구조를 가지며, 이는 실제 풍력발전기 운영 환경의 통계적 특성을 반영한다.

모델 학습과 평가를 위해 데이터는 학습, 시험 세트로 분할하였다. 이상감지 모델 학습에는 정상 영상만을 사용하여, 각 4가지 영상 스트림에 대해 400장, 총 1600장의 학습 데이터를 통해 정상 패턴을 학습하는 one-class 기반 학습 구조를 구성하였다. 시험 세트는 정상 데이터와 실제 화재 상황을 모사한 마스킹을 0.5 ratio로 하여 추가된 각 영상 스트림에 대해 120장의 정상 데이터를 통해 총 480장의 합성 이상 데이터를 사용하여 최종 성능 평가에 활용하였다. 합성 이상 데이터는 단순한 노이즈 기반 또는 랜덤 마스킹 기반의 합성 이상 데이터를 사용하더라도 정상과 이상 간의 feature 분리를 효과적으로 학습할 수 있음이 보고되고 있다. 특히 DRAEM [13]과 같은 방법은 물리적으로 정밀한 결함 모델링 없이도 단순한 합성 이상 패턴을 통해 산업 결함 검출에서 우수한 성능을 달성하였다. 따라서 본 연구에서는 물리적 재현보다는 다양한 이상 패턴을 생성하여 모델의 일반화된 이상 탐지 능력을 향상시키는데 초점을 두었다. 데이터셋 구성 예시는 그림 2에 나타났다.



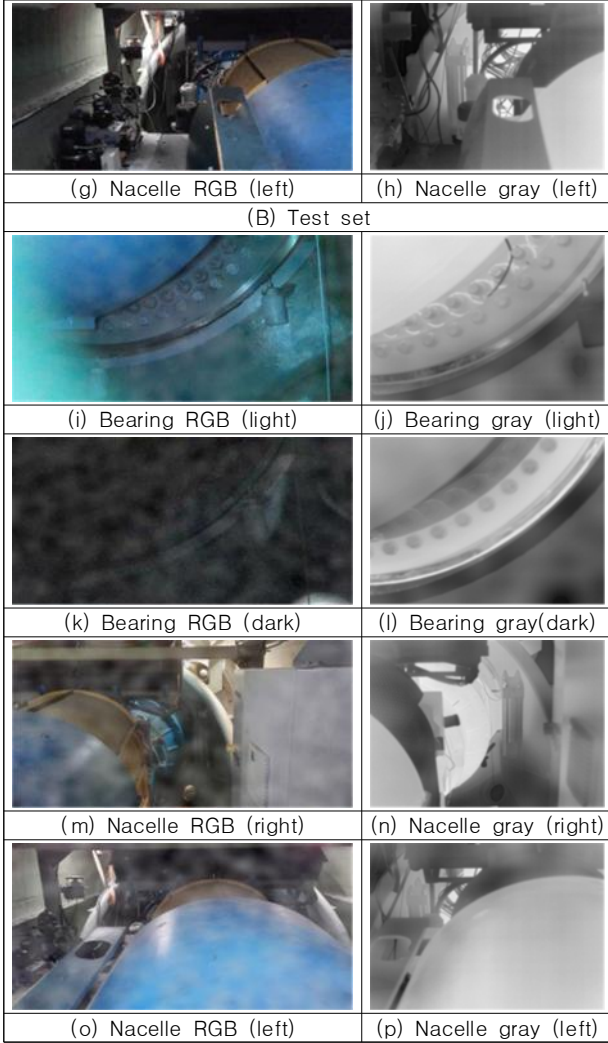


Fig. 2. Overall training dataset & test dataset

V. Result & Discussion

1. Evaluation Metrics

본 연구는 이상 탐지와 이상 국소화를 동시에 평가하기 위해 image-level 및 pixel-level 지표를 함께 사용하였다. Image-level 성능은 AUROC로 평가하였고, pixel-level 성능은 pixel AUROC 그리고 AUPRO(Area Under Per-Region Overlap)로 평가하였다. 특히 AUPRO는 anomaly map의 국소화 품질을 FPR(거짓 양성률) 상한 구간에서 적분하여 계산하는 지표로, 산업 결함 및 이상 세그멘테이션 벤치마크에서 널리 사용되어 본 연구에서 차용하였다.

AUPRO 계산을 위해 먼저 임계값 t 에서의 예측 이상 픽셀 집합을 $P_{ano}(t)$ 라 하고, 테스트 이미지 i 의 ground-truth 이상 영역 집합을 $\{C_{i,j}\}_{j=1}^{k_i}$ 라 하면,

Per-Region Overlap(PRO)는 다음과 같이 정의된다:

$$PRO(t) = (1/\sum_i k_i) \sum_i \sum_{j=1}^{k_i} \frac{P_{ano}(t) \cap C_{i,j}}{|C_{i,j}|}$$

이후 PRO를 FPR에 대해 적분하여 AUPRO를 계산하며, $FPR \leq 0.05$ 구간에서 적분한다:

$$AUPRO = \int_0^{0.05} PRO(FPR) dFPR$$

또한 산업 운영 관점에서는 낮은 오탐 조건에서의 탐지 성능이 중요하므로, 본 연구는 고정 FPR 조건에서의 TPR(FPR = 5%에서의 TPR) 또한 함께 보고한다.

2. Quantitative Performance Comparison

본 연구에서는 나셀 내부 화재감시 환경에서의 이상 탐지 성능을 평가하기 위해 경계 기반 방법(OCSVM), 밀도 기반 방법(LOF), 분포 기반 방법(PaDiM), 메모리 기반 방법(PatchCore)을 동일한 특징 공간에서 비교하였다. 실험 데이터는 서로 다른 연기 특성과 배경 조건을 반영하기 위해 네 개의 데이터셋으로 구성되었으며, 실제 운영 환경에서 발생할 수 있는 다양한 화재 상황을 모사하기 위해 데이터셋간 결과를 가중 평균 방식으로 통합하여 최종 성능을 평가하였다.

데이터셋 통합을 위해 각 데이터셋에서 계산된 anomaly score에 가중치 λ_i 를 적용하여 다음과 같은 앙상블 점수를 정의하였다.

$$S_{ensemble}(x) = \lambda_1 S_1(x) + \lambda_2 S_2(x) + \lambda_3 S_3(x) + \lambda_4 S_4(x)$$

여기서 $S_i(x)$ 는 dataset i 에서 계산된 anomaly score이며, λ_i 는 각 데이터셋의 중요도를 반영하는 가중치이다. 또한 $\sum \lambda_i = 1$ 을 만족하도록 설정하였다.

Table 1. Metrics comparison of anomaly detection methods using the weighted ensemble evaluation

Method	Image AUROC	Pixel AUROC	AUPRO	F1 score
OCSVM	0.77	0.69	0.45	0.56
LOF	0.94	0.80	0.59	0.67
PaDiM	0.91	0.78	0.37	0.69
PatchCore	0.96	0.83	0.49	0.71

표 1은 이러한 가중치 기반 앙상블 평가 결과를 나타낸다. 결과를 보면 메모리 기반 PatchCore가 대부분의 평가

지표에서 우수한 성능을 보였으며, 전반적으로 안정적인 성능을 확인할 수 있다. Patch-Core는 Image AUROC 0.96, Pixel AUROC 0.83, AUPRO 0.49, MaxF1 0.71을 기록하여 다른 이상 탐지 방법들을 전반적으로 상회하였다. 경계 기반 방법인 OCSVM은 정상 분포를 단일 결정 경계로 근사하는 구조적 특성으로 인해 복잡한 정상 특징 분포를 충분히 모델링하지 못하여 상대적으로 낮은 성능을 보였다. 밀도 기반 방법인 LOF는 국소 밀도 변화를 기반으로 이상을 탐지하기 때문에 비교적 높은 image-level 탐지 성능을 보였으나, 전역적인 feature 분포를 충분히 반영하지 못하는 한계로 인해 pixel-level 지표에서는 PatchCore보다 낮은 성능을 나타냈다. 분포 기반 방법인 PaDiM은 위치별 평균과 공분산을 이용한 통계적 모델링을 통해 안정적인 탐지 성능을 보였으나, 다양한 도메인 특성을 동시에 반영하기에는 한계가 있다.

반면 PatchCore는 정상 패치 임베딩을 메모리 뱅크로 저장하고 최근접 거리 기반으로 이상을 판단 하는 비모수적 모델링 구조를 가지기 때문에 복잡하고 다봉 형태를 갖는 정상 특징 분포를 효과적으로 근사할 수 있다. 특히 여러 데이터셋에서 학습된 특징 표현을 앙상블 방식으로 결합함으로써 다양한 연기 패턴과 조명 조건에 대한 일반화 성능이 향상되었으며, 그 결과 다른 방법들보다 우수한 이상 탐지 성능을 나타낸 것으로 해석된다.

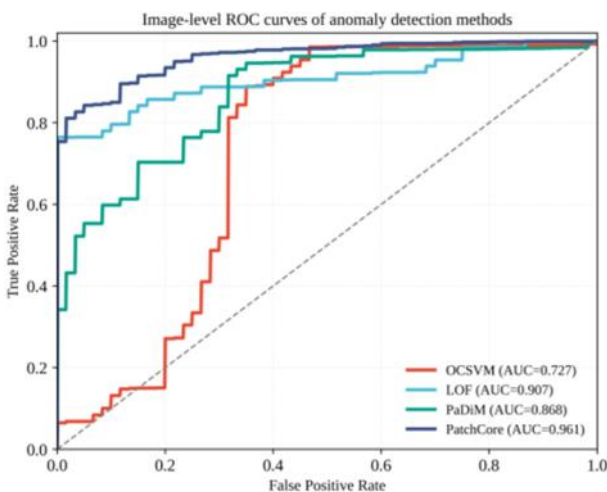


Fig. 3. metrics comparison of single anomaly detection Image-level ROC curves

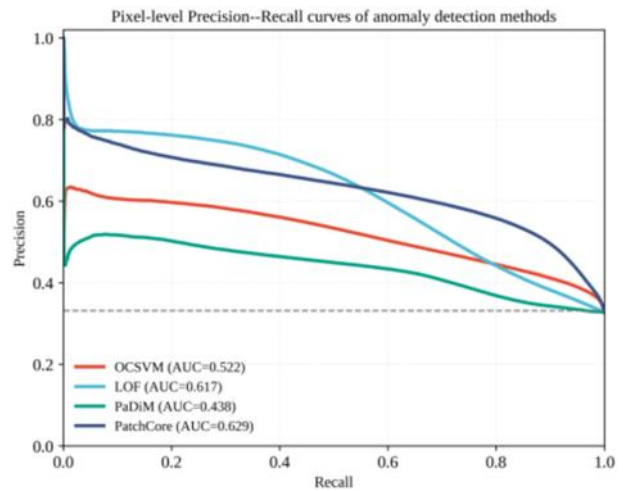


Fig. 4. metrics comparison of single anomaly detection pixel-level Precision-Recall curves

그림 3, 4는 다중 입력을 결합한 ensemble 성능이 아니라, 단일 카메라 입력(베어링 RGB 데이터)에 대해 각 이상 탐지 모델이 독립적으로 수행한 결과를 비교한 것이다. 해당 결과는 진단 시스템의 결함으로 4개의 입력 중 일부 데이터만 수집 가능할 때, 이상 여부를 안정적으로 판별하고 이상 위치를 정밀하게 국소화할 수 있는지를 평가하는데 있다. image-level ROC curve를 보면 PatchCore는 AUROC 0.961로 비교 대상인 OCSVM 0.727, LOF 0.907, PaDiM 0.868보다 가장 높은 성능을 기록하였다. 특히 ROC 곡선이 전반적으로 좌상단에 가깝게 분포한다는 점은, 단일 입력 영상만 주어진 상황에서도 PatchCore가 정상과 이상 샘플을 안정적으로 구분하고 있음을 의미한다. 또 낮은 FPR 구간에서 PatchCore가 높은 TPR를 유지하는 점은 단일 입력 내에서 정상 패턴의 분포를 기억하고, 테스트 패치가 정상 분포로부터 얼마나 벗어나는지를 거리 기반으로 정량화하기 때문에 가능한 결과로 해석된다.

Pixel-level precision-recall curve에서도 유사한 경향이 나타나 PatchCore는 AUPRC 0.629로 가장 높은 값이 나타난다. PR curve를 보면 PatchCore는 낮은 recall 영역뿐 아니라 중간 recall 영역에서도 비교적 높은 precision을 유지한다.

해당 결과는 PatchCore가 ensemble 후 성능이 높은 것 뿐만 아니라, ensemble 이전의 각 단일 입력 단계에서도 이미 높은 완성도의 이상 탐지 결과를 생성할 수 있음을 보여준다.

이러한 결과들은 나셀 내부와 같이 반복 구조와 금속 반사 특성이 강하게 나타나는 산업 환경에서 메모리 기반 패

치 임베딩 비교 방식이 경계 기반 또는 단일 분포 기반 모델보다 정상 상태를 보다 효과적으로 모델링할 수 있음을 시사한다.

3. Performance form an Operational Perspective

AUROC와 AUPRC는 threshold-independent 지표로서 모델의 전반적인 분류 성능을 평가하는데 유용 하지만, 실제 감시 시스템은 특정 임계값에서 동작한다. 따라서 실제 운영환경에서의 신뢰성을 평가하기 위해, 본 연구에서는 낮은 오탐 구간에서의 성능을 나타내는 operating-point 지표를 추가로 분석하였다. 구체적으로 FPR = 5% 조건에서의 TPR과 TPR = 95%를 만족하기 위해 필요한 FPR을 평가하였다.

Table 2. Operating point metrics under low false alarm constraints with weighted ensemble evaluation

Method	TPR@FPR = 5%	FPR@TPR = 95%
OCSVM	0.069	0.454
LOF	0.765	0.650
PaDiM	0.553	0.345
PatchCore	0.843	0.188

표 2는 운영 시나리오 가중치를 적용한 operating point 성능 비교 결과를 나타낸다. 낮은 오탐 조건 (FPR = 5%)에서의 탐지율 기준으로는 PatchCore가 TPR = 0.843로 가장 높은 값을 기록하였으며, LOF가 그 뒤를 이었다. 이는 PatchCore가 엄격한 오탐 제약 조건에서도 높은 탐지 민감도를 유지할 수 있음을 의미한다. 반면 OCSVM은 TPR = 0.069로 낮은 탐지율을 보여 실제 운영 환경에서의 적용 가능성이 제한적임을 확인할 수 있다.

또한 FPR@TPR = 95% 기준에서도 PatchCore는 0.188로 가장 낮은 값을 기록하였다. 이는 높은 탐지율을 확보하면서도 다른 방법들보다 적은 오탐률로 운영이 가능함을 의미한다. 반면 LOF는 FPR@TPR = 95% = 0.650으로 높은 오탐률을 나타냈는데, 이는 국소 밀도 기반 방법의 특성상 정상 데이터 내부의 밀도 변동에도 민감하게 반응하기 때문으로 해석된다.

PaDiM은 위치별 평균과 공분산을 이용한 통계적 분포 모델링을 기반으로 비교적 안정적인 성능을 보였으나, 연기와 같은 비정형 패턴의 분포 변화를 완전히 설명하기에는 한계가 있는 것으로 나타났다. 특히 연기 패턴은 공간적으로 넓게 확산되는 특성을 가지기 때문에 단일 가우시안 분포 기반 모델링에서는 이러한 변화를 충분히 반영하지 못할 가능성이 있다.

반면 PatchCore는 정상 패치 임베딩을 메모리 뱅크로 저장하고 최근접 거리 기반으로 이상 여부를 판단한다. 이러한 구조는 나셀 내부 영상과 같이 반복적인 구조와 복잡한 반사 특성이 존재하는 환경에서 정상 feature 분포를 보다 유연하게 표현할 수 있다는 장점을 가진다.

종합하면, 운영 시나리오 기반 가중치 평가에서 PatchCore는 낮은 오탐 조건과 높은 탐지 민감도를 동시에 만족하는 안정적인 성능을 보였다. 이는 실제 화재 감시 시스템과 같은 조기 경보 환경에서 PatchCore 기반 접근이 다른 이상 탐지 방법들보다 효과적으로 활용될 수 있음을 시사한다.

VI. Conclusion

본 연구에서는 풍력터빈 나셀 내부에서 발생할 수 있는 화재를 조기에 탐지하기 위한 이미지 기반 이상 탐지 방법을 제안하였다. 풍력터빈 나셀 내부는 제한된 공간 구조와 복잡한 배경 환경을 가지며, 실제 화재 데이터의 수집이 어렵다는 문제로 인해 일반적인 지도 학습 기반 접근법을 적용하기 어렵다. 이러한 문제를 해결하기 위해 본 연구에서는 정상 데이터만을 이용하여 이상을 탐지할 수 있는 메모리 기반 이상 탐지 모델인 PatchCore를 활용하여 풍력터빈 나셀 내부 화재 감지를 위한 anomaly segmentation 구조를 설계하였다.

Image-level ROC 분석 결과 PatchCore는 AUROC 0.96로 가장 높은 성능을 보였으며, LOF (0.94), PaDiM (0.91), OCSVM (0.77)보다 우수한 이상 판별 능력을 나타냈다. 또한 pixel-level precision-recall 분석에서도 PatchCore는 AUPRC 0.629로 가장 높은 값을 기록하여 이상 영역의 위치를 보다 정확하게 국소화할 수 있음을 확인하였다.

본 실험 결과는 다음과 같은 시사점을 제공한다. 첫째, 풍력터빈 나셀 내부와 같이 다봉 및 비선형 feature 분포를 가지는 산업 환경에서는 비모수적 최근접 거리 기반 모델링이 구조적으로 유리하다. 둘째, 이상 탐지 성능은 모델 구조뿐 아니라 feature representation의 도메인 적합성에 크게 의존한다. 셋째, pixel level 세그멘테이션 지표의 향상은 단순 탐지 성능 개선을 넘어 실제 운영 환경에서의 공간적 이상 식별 정확도 향상으로 이어진다.

따라서 본 연구는 PatchCore 기반 메모리 모델링 프레임워크가 풍력터빈 나셀 내부 화재 감지에 효과적으로 활용될 수 있음을 확인하였다.

ACKNOWLEDGEMENT

This research was supported by the Korea Institute for Advancement of Technology(KIAT) grand funded by the Ministry of Trade, Industry, and Energy(MOTIE), Korea.(P0025331)

This work was supported by a project (R23EG02) of the Korea Electric Power corporation Research Institute (KEPRI).

REFERENCES

- [1] Fei You, Sujan Shaik, Md Rokonzaman, Kazi Sajedur Rahman, and Wen-Shan Tan. "Fire risk assessments and fire protection measures for wind turbines: A review." *Heliyon*, 9(9), 2023.
- [2] Xiaoyuan Liu, Senxiang Lu, Yan Ren, and Zhenning Wu. "Wind turbine anomaly detection based on scada data mining." *Electronics*, 9(5), 2020.
- [3] Eric Stefan Miele, Fabrizio Bonacina, and Alessandro Corsini. "Deep anomaly detection in horizontal axis wind turbines using graph convolutional autoencoders for multivariate time series." *Energy and AI*, 8:100145, 2022.
- [4] Anping Wan, Wenbin Gong, Khalil AL-Bukhaiti, Xiaomin Cheng, Xiaosheng Ji, Yunsong Ji, and Shidong Ma. "Data-driven early fire detection in offshore wind turbines: A tcn-eca based approach leveraging scada data". *Process Safety and Environmental Protection*, 200:107373, 2025.
- [5] Jack P. Salameh, Sebastien Cauet, Erik Etien, Anas Sakout, and Laurent Rambault. "Gearbox condition monitoring in wind turbines: A review." *Mechanical Systems and Signal Processing*, 111:251-264, 2018.
- [6] Francesco Castellani, Francesco Natili, Davide Astolfi, and Yolanda Vidal. "Wind turbine gearbox condition monitoring through the sequential analysis of industrial scada and vibration data." *Energy Reports*, 12:750-761, 2024.
- [7] Eun Chan Do, Su Hyun Park, and Ki Yong Oh. "Hierarchical deep neural network for fire detection in wind turbine nacelles." *Journal of the Korean Society for Nondestructive Testing*, 44(4):268-277, 2024.
- [8] Minsoo Lee, Eun Do, Moon-Woo Park, and Ki-Yong Oh. "A novel fire detection and suppression system for the surveillance of a wind turbine nacelle." *International Journal of Intelligent Systems*, 2025, 05 2025.
- [9] Chon H, Oh D, Noh J. "Enhanced Prediction Performance of Internal Defect Detection in Wind Turbine Blades on Thermography Using Deep Learning Models with Preprocessed Synthetic Data." *Applied Sciences*, 15(6):3042, 2025.
- [10] Eunhee Cho, Somi Jin, Byeonghwan Jeon, and IN KYU PARK. "Augmentation of defect image data using gan." *Journal of the Institute of Electronics and Information Engineers*, 59(10):98-108, 2022.
- [11] Yinan Wang, Ryota Yoshihashi, Rei Kawakami, Shaodi You, Tohru Harano, Masahiko Ito, Katsura Komagome, Makoto Iida, and Takeshi Naemura. "Unsupervised anomaly detection with compact deep features for wind turbine blade images taken by a drone". *IPSI Transactions on Computer Vision and Applications*, 11(1):3, 2019.
- [12] Jianfeng Huang, Chenyang Li, Yimin Lin, and Shiguo Lian. "Unsupervised industrial anomaly detection via pattern generative and contrastive networks." *arXiv preprint arXiv:2207.09792*, 2022.
- [13] Zavrtnik, V, Kristan, M, Skočaj, D, "DRAEM: A discriminatively trained reconstruction embedding for surface anomaly detection." *ICCV*, 2021.

Authors



DoHyeong Kim received the B.S. degrees in Mechanical Engineering from Incheon National University, Korea in 2023, and received the M.S. degrees in Mechanical Engineering from KyungHee University,

Korea, in 2025, respectively. Kim is currently a researcher at KEPRI. His expertise includes Anomaly Detection, Python-based Automation. He is actively leading projects involving real-time system monitoring and the integration of Linux server architectures for advanced AI agent frameworks.



SeungWoo Son received the B.S., M.S. degrees in Electrical Engineering from Konkuk University, Korea, in 2018, and 2020, respectively. Son is currently a senior researcher in KEPRI.

He is interested in renewable energy with A.I. and power system economics.



SunHo Park received his B.S., M.S., and Ph.D. degrees in Mechanical Engineering from Pohang University of Science and Technology(POSTECH), Republic of Korea, in 2003, 2005 and 2010, respectively.

His doctoral research focused on the design of wind turbine blades using finite element modeling. Dr. Park is currently a Principal Researcher at the Korea Electric Power Corporation Research Institute (KEPRI), where he leads research and development projects related to offshore wind turbine operation and maintenance technologies and provides technical advisory support for offshore wind business initiatives developed by KEPCO and Korea Offshore Wind Power (KOWP).