

파이프라인 누출 탐지를 위한 컨볼루션 뉴럴 네트워크를 이용한 유연 음향 방출 센서 신호 분류

Flexible Acoustic Emission Sensor Signal Classification Using Convolutional Neural Networks for Pipeline Leak Detection

박병재^{1,*}
Byungjae Park^{1,*}

¹ 한국기술교육대학교 기계공학부 (School of Mechanical Engineering, Korea University of Technology and Education)
Corresponding Author / E-mail: bjp@koreatech.ac.kr
ORCID: 0000-0002-8952-0736

KEYWORDS: Acoustic emission (음향 방출), Spectrogram (스펙트로그램), Convolutional neural network (컨볼루션 뉴럴 네트워크), Pipeline monitoring (파이프라인 모니터링)

This paper presents a method for the real-time detection of pipeline leaks using flexible Acoustic Emission (AE) sensors. The signals gathered from the AE sensor are transformed into RGB images through the application of Mel-spectrogram and color coding. These converted images serve as input for a Convolutional Neural Network (CNN) based on ResNet18. With this approach, both the presence and intensity of leaks in a pipeline can be identified using the AE sensor. The effectiveness of the proposed method was validated through data collected from a testbed featuring a galvanized pipe.

Manuscript received: February 14, 2025 / Revised: June 24, 2025 / Accepted: August 30, 2025

1. 서론

파이프라인은 플랜트 등 제조 시설에서 액체와 기체를 수송하는 데 널리 사용된다. 파이프라인이 다양한 요인으로 손상되면 대량의 액체나 기체가 유출되어 환경 오염과 경제적 손실을 초래한다. 이를 예방하려면 파이프라인의 실시간 모니터링이 필요하다. 여러 기법이 실시간 모니터링에 활용되고 있다.

음향 방출(Acoustic Emission, AE) 센서는 재료 내부에서 발생하는 미세 균열, 변형, 마찰 등에 의해 생성되는 고주파 탄성파를 실시간으로 감지하는 비파괴 검사(Nondestructive Evaluation, NDE)에 사용된다. AE 센서는 주로 압전효과를 이용하여 탄성파를 전기 신호로 변환하며, 이를 통해 구조물 내부의 손상 발생 및 진행 상황을 모니터링할 수 있다[1]. AE 센서는 높은 감도와 빠른 응답 특성을 가지므로, 미세한 변화를 조기에 검출할 수 있는 장점을 가진다. 그리고 AE 센서는 기존의 초음파 검사 등 다른 NDE 기법에 비해 설치가 간편하고 실시간 모니터링 시스템에

적합하다[2]. 그러나 외란 신호와의 구분, 신호 전파 경로의 복잡성 등으로 인해 여러 가지 신호 처리 기법의 적용을 필요로 한다.

AE 파이프라인 표면에 부착하여 소음을 측정할 수 있다. AE 센서는 작은 소음까지 탐지할 수 있고, 크기가 작아 설치가 용이하다. 그러나 노이즈의 영향을 많이 받는 단점이 있다. 이 문제를 해결하기 위해 AE 신호를 활용한 다양한 방법이 제안되었다.

AE 센서를 이용하여 파이프라인의 누출을 탐지하기 위해서 머신 러닝을 이용한 다양한 방법이 제안되어 왔다. 힐베르트-황 변환(Hilbert-huang Transform, HHT)과 도착 시간 차 분석(Time Difference Of Arrival, TDOA)을 기반으로 파이프라인 모니터링 시스템에서 타깃 위치를 추정하는 방법이 제안되었다[3]. 튜닝된 웨이블릿 변환을 통해 물이 충전된 플라스틱 파이프 내 AE 신호의 시간 및 주파수 특성을 정밀하게 분석하여 누출 검출 성능을 향상시키는 방법이 제안되었다[4]. 러프 셋 이론을 활용하여 데이터 차원을 축소한 후 인공벌집(Artificial Bee Colony, ABC) 알고리즘으로 최적화된 서포트 벡터 머신(Support Vector




Fig. 1 Acoustic emission signals

Machine, SVM)을 적용해 누출 여부를 분류, 오탐률을 낮추는 접근법이 제안되었다[5]. 동적 압력 송신기와 웨이블릿 패킷 엔트로피(Wavelet Packet Entropy, WPE)를 결합하여 장거리 가스 파이프라인에서 누출을 탐지하는 방법이 제안되었다[6]. 최적의 웨이블릿 변환과 SVM을 이용해 가스 파이프라인의 누출 상태를 매우 높은 정확도로 분류하는 방법이 제안되었다[7].

최근 들어 파이프라인 누출 탐지에 딥러닝을 적용한 여러 가지 방법들이 제안되고 있다. 다중 스케일 멀티스케일 컨볼루션 네트워크(Multiscale Fully Convolutional Networks, MFCN)을 활용하여 도시 상수도 네트워크의 누출 탐지 및 물 손실 관리 시스템을 구현하는 방법이 제안되었다[8]. 롱-텀 숏-텀 메모리 네트워크(Long Short Term Memory Network, LSTM) 오토 인코더(Auto Encoder)와 1-Class SVM을 결합한 반지도 학습 기법을 통해 천연가스 파이프라인의 누출을 높은 정확도로 검출하는 방법이 제안되었다[9]. CNN과 양방향 LSTM (Bidirectional Long-term Short-term Memory, BiLSTM)을 결합하여 공간적 및 시간적 특징을 효과적으로 모델링함으로써 가스 누출의 발생 및 크기 분류를 신속하게 수행하는 방법이 제안되었다[10]. 푸리에(Fourier) 변환 기반 스펙트로그램과 최적화된 CNN을 결합하여 파이프-인-파이프(Pipe-in-Pipe, PIP) 구조 내 열 및 기체의 누출 문제를 해결하는 방법이 제안되었다[9]. 누출 민감도 지표와 1-D CNN을 결합하여 다양한 유체 압력 조건 하에서도 누출 발생 및 크기를 정확하게 식별하는 방법이 제안되었다[11].

앞에서 언급한 대부분의 방법은 AE 신호를 시간-도메인과 주파수-도메인에서 다양한 피처를 추출하는 전처리 과정을 거친다. 멜-스펙트로그램은 신호의 시간-주파수 특성을 동시에 시각화 한 것으로 신호를 이미지 형태로 표현할 수 있기 때문에 AE 신호의 시간-주파수 공간에서의 패턴을 잘 표현할 수 있는 장점이 있다[12]. 멜-스펙트로그램은 이미지와 유사한 형태를 가지고 있기 때문에 이미지를 처리하는 방식과 같은 방법으로 CNN 모델의 입력으로 사용할 수 있다[9,13,14].

본 논문에서는 파이프라인 누출을 탐지하기 위해 컨볼루션 뉴럴 네트워크(Convolutional Neural Network, CNN)를 사용하는 방법을 제안한다. 제안하는 방법은 AE 신호를 이미지 형태로 변환한 후 CNN에 입력한다. 그리고 수집한 AE 신호를 변환하는 과정에서 컬러 코딩을 사용하여 기존의 검증된 이미지 처리 모델을 활용할 수 있도록 한다. 제안하는 방법은 두 가지 장점을 가지고 있다. 1) 전통적인 머신 러닝 기반의 방법과 달리 신호 처리를 위한 피처 엔지니어링(Feature Engineering)을 필요로 하지 않는다. 2) 신호 처리를 위하여 검증된 이미지 분류를 위한 CNN 모델 구조를 활용할 수 있다.

이 방법은 누출 발생과 누출 강도를 분류할 수 있다. 구축한 테스트베드에서 수집한 데이터 셋을 이용해 제안한 방법의 성능을 검증하였다.

본 논문은 다음과 같이 구성된다. 2장에서는 관련 연구를 소개한다. 3장과 4장에서는 제안하는 방법에 대해 설명과 제안하는 방법의 성능을 보여준다. 5장에서는 결론과 향후 과제를 논의한다.

2. 파이프라인 누출 탐지

본 논문에서 제안하는 파이프라인 누출 탐지 방법은 다음 두 단계로 구성된다. 1) AE 신호의 이미지 변환, 2) CNN을 이용한 정상 및 비정상 상태 분류.

2.1 AE 신호 변환

AE 신호를 이미지 형태로 변화시키기 위하여 제안하는 방법에서는 멜-스펙트로그램(Mel-sepectrogram)을 사용하였다[12]. 멜-스펙트로그램은 신호의 시간-주파수 특성을 시각화 한 것으로 신호를 이미지 형태로 표현할 수 있다. 멜-스펙트로그램은 신호의 시간-주파수 특성을 인간의 청각 특성을 고려할 수 있도록 변환된 이미지 형태의 주파수 축을 멜 스케일을 적용한다. AE 신호를 멜-스펙트로그램을 이용해 이미지 형태로 변환하기 위해서는 다음과 같은 절차를 거친다. 1) 단시간 푸리에 변환(Short Time Fourier Transform, STFT), 2) 파워 스펙트럼 계산, 3) 멜 필터 적용.

STFT는 입력 신호 $x[n]$ 에 대해서 짧은 시간 윈도우를 적용하여 시간-주파수 영역으로 변환한다.

$$X(m, k) = \sum_{n=0}^{N+1} x_m[n] e^{-j2\pi \frac{kn}{N}} \quad (1)$$

식(1)에서 m 은 프레임 인덱스, k 은 주파수 히스토그램 bin의 인덱스, 그리고 $x_m[n]$ 은 m 번째 신호 프레임이다. SFFT에 의해 변환된 신호 프레임을 바탕으로 파워 스펙트럼을 계산한다.

$$P(m, k) = |X(m, k)|^2 \quad (2)$$

멜-스펙트럼은 삼각형 형태의 필터를 적용하여 구한다.




Fig. 2 Plasma color-coded Mel-Spectrogram of an acoustic emission signal

Table 1 ResNet18-based model

Layer name	Output size	Layers
conv1	112×112	-
conv2_x	56×56	$2 \times [3 \times 3, 64]$
conv3_x	28×28	$2 \times [3 \times 3, 128]$
conv4_x	14×14	$2 \times [3 \times 3, 256]$
conv5_x	7×7	$2 \times [3 \times 3, 512]$
Output	1×1	average pool, 6-d fc, softmax
FLOPs		2.55×10^9

Table 2 Hyper parameters

Name	Value
Image size (H × W)	128×256
Batch size	256
Num. epoch	900
Learning rate	$1.0e-6$

$$S(m, i) = \sum_{k=0}^{N-1} P(m, k) H_i(f_k) \quad (3)$$

식(3)에서 H_i 와 f_k 는 멜-필터와 k 번째 주파수 히스토그램 빈의 인덱스에 해당하는 주파수를 의미한다. 사용된 멜-필터 멜 스케일에 따라 식(4)와 같이 계산된다.

$$H_i(f) = \begin{cases} \frac{f - f_{i-1}}{f_i - f_{i-1}} & f_{i-1} \leq f \leq f_i \\ \frac{f_{i+1} - f}{f_{i+1} - f_i} & f_i \leq f < f_{i+1}, \\ 0, & \text{otherwise} \end{cases} \quad (4)$$

식(4)에서 f_{i-1} , f_i , f_{i+1} 은 i 번째 필터의 각각 최소, 중간, 최고 주파수를 의미하며 멜 스케일과 주파수의 관계는 식(5)와 같다.




Fig. 3 Testbed

$$f = 700 \left(10^{\frac{m}{2595}} - 1 \right) \quad (5)$$

멜-스펙트럼의 값은 로그를 취하여 최종적으로 구해지게 된다.

$$L(m, i) = \log(S(m, i) + \varepsilon) \quad (6)$$

2.2 CNN을 이용한 누출 여부 및 누출 강도 탐지

제안하는 방법은 멜-스펙트로그램 이미지를 분류할 수 있도록 CNN을 훈련시켜 파이프라인에 발생한 누출 여부 및 누출 강도를 탐지한다. 이미지 분류를 위한 CNN 사용하는 경우 다음과




Fig. 4 Confusion matrices of the proposed method and the other methods

같은 장점이 있다. 1) 이미지 분류를 위해 프리-트레이닝(Pre-training)이 완료된 다양한 모델이 공개되어 있다. 2) 이미지 증강(Augmentation)을 위한 다양한 기법을 활용하는 것이 가능하다. 제안하는 방법에서는 공개된 모델 중 ResNet18을 바탕으로 CNN을 구성하였다.

ResNet은 CNN의 네트워크 모델의 깊이가 깊어짐에 따라 발생하게 되는 기울기 소실(Vanishing Gradient) 이슈를 해결하기 위해 제안되었다[15]. ResNet의 단위 모듈인 레지듀얼 블록은 스킵 커넥션(Skip Connection)을 가지고 있다. 스킵 커넥션은 컨볼루션 레이어(Convolutional Layer)를 거치지 않는 통로를 제공하여 역전파(Backpropagation) 과정에서 그래디언트(Gradient)를 흐름에 도움을 준다[16]. 레지듀얼 블록을 사용하면 네트워크 모델의 깊이가 깊은 네트워크를 구성할 수 있다. 다양한 모델이 공개되어 왔지만 ResNet은 이미지 분류나 이미지를 처리하는 다양한 작업의 베이스라인으로 사용되고 있다. Table 1에는 제안하는 방법에서 사용하는 CNN의 구조를 보여주고 있다. CNN 모델에서 출력(Output) 레이어의 출력 채널 숫자가 파이프라인에 발생한 누출을 탐지하기 위하여 변경되었으며 이에 따라 플롭스(Floating Point Operations Per Second, FLOPS) 값이

Table 3 Accuracy and F1 scores

	Accuracy	F1 score
Proposed	0.930	0.930
SVM	0.866	0.867
Decision tree	0.854	0.875
MLP	0.876	0.875

변경되었다.

ResNet18 기반의 CNN을 멜-스펙트로그램 이미지를 이용해 훈련시키는 과정에서 두 가지 추가적인 이슈가 존재한다. 첫 번째 이슈는 멜-스펙트로그램의 각 셀 값은 dB 단위로 나타나기 때문에 일반적인 이미지의 픽셀이 가지고 있는 값의 범위와 매우 다르다는 것이다. 이로 인해 전이 학습(Transfer Learning)을 이용해 프리-트레이닝이 완료된 값을 가져와 사용하더라도 ResNet18의 cov1 레이어를 새로 만들어야 하기 때문에 CNN의 학습이 효과적으로 진행되지 않을 수 있다. 두 번째 이슈는 ResNet18은 3개 채널을 가진 이미지를 입력으로 사용하는데 비해 멜-스펙트로그램 이미지는 1개의 채널을 가지고 있다는 것이다.

Table 4 Color coding

Colormap	Accuracy	F1 Score
Grayscale	0.917	0.917
Plasma	0.930	0.930

이 이슈를 해결하기 위하여 다음과 같은 과정을 통해 멜-스펙트로그램을 전처리 한다. 1) 멜-스펙트로그램 이미지의 픽셀 값들을 그레이 스케일 이미지의 범위로 정규화 한다. 2) 1개 채널을 가진 그레이 스케일 이미지화 된 멜-스펙트로그램을 컬러 코딩을 통해 3개 채널을 가진 RGB 이미지로 변환한다. 제안하는 방법에서 컬러 코딩은 플라스마 컬러맵(Plasma Colormap)을 이용한다.

$$\begin{aligned}
 R(S) &= 0.058 + 1256S - 0.816S^2 + 0.721S^3 \\
 G(S) &= 0.644S + 0.680S^2 - 1.385S^3 \\
 B(S) &= 0.077 + 2.105 - 3.023S^2 + 2.176S^3 \\
 S &= \frac{S_{uint8}}{255}
 \end{aligned} \quad (6)$$

식(6)에서 $R(S)$, $G(S)$, $B(S)$ 는 각각 RGB 채널의 값이고 S_{uint8} 는 그레이 스케일로 정규화된 멜-스펙트로그램 셀의 값이다.

제안하는 방법은 파이프라인의 누출을 재연할 수 있는 테스트베드에서 수집되었다. 테스트베드는 플랜트에서 널리 사용되는 35 mm 아연 도금 파이프를 이용하여 구성하였다(Fig. 2). Fig. 2는 전처리가 완료된 멜-스펙트로그램 이미지이다. 컬러 코딩을 통해 다른 셀 보다 신호 강도가 강한 셀들이 좀 더 잘 드러나는 것을 확인할 수 있다.

파이프라인의 누출을 연출하기 위하여 파이프의 이음새 부분을 느슨하게 만들었으며 누출 정도는 파이프라인에 주입되는 질소의 압력을 이용해 조절하였다. 누출이 발생하는 부위에서 15 cm 떨어진 부분에 AE 센서를 부착하였다[17]. 질소 압력을 조절하여 발생시킨 누출의 크기는 총 6단계로 0, 2, 4, 6, 8, 10 ml/min.이다. AE 센서로부터 수집된 신호를 증폭하기 위해 프리 앰프(40dB)에 연결한 200 KHz로 샘플링 하였다.

3. 실험 결과

3.1 데이터셋

훈련 및 테스트 데이터셋은 누출 크기가 0 l/min.인 정상 상태와 누출 크기의 강도가 2, 4, 6, 8, 10 l/min.인 5단계의 누출 상태 총 6개의 클래스로 이루어져 있다. 훈련 데이터셋의 경우 총 7,800개의 데이터 포인트를 가지고 있으며 테스트 데이터셋의 경우 3,000개의 데이터 포인트가 포함되어 있다.

3.2 성능

제안한 방법의 CNN은 PyTorch로 구현되었으며 7,200장의

멜-스펙트로그램 이미지를 사용해 1대의 Nvidia RTX A5000로 학습되었다. CNN의 파라미터를 업데이트 하기 위한 옵티마이저(Optimizer)는 AdamW [18]를 사용하였고 매 300 에폭(Epoch)마다 러닝 레이트(Learning Rate)를 1/10씩 감소시켰다. 학습에 사용한 하이퍼파라미터(Hyperparameter)는 Table 2에 나타나 있다.

제안한 방법의 누출 탐지 성능을 SVM, 디시전 트리(Decision Tree, DT), 그리고 멀티-레이어드 퍼셉트론(Multi-layered Perceptron, MLP)의 누출 탐지 성능과 비교하였다. 세 가지 방법 모두 AE 신호의 시간-도메인과 주파수-도메인에서 피쳐를 추출하였다[18]. 시간-도메인에서 신호 강도의 평균, 표준편차, 루트 민 스퀘어(Root Mean Square, RMS), 그리고 피크(Peak) 피쳐를 추출하였다. 주파수-도메인에서는 주파수의 무게 중심, 피크 주파수, 그리고 평균 주파수를 추출하였다. 성능 비교를 위한 SVM은 라디얼 커널 함수(Radial Kernel Function)를 사용하였다. 성능 비교를 위해 사용된 MLP의 하이퍼 파라미터는 경우 히든 레이어(Hidden Layer)의 크기는 100이며 러닝 레이트와 옵티마이저는 각각 0.001과 Adam [18]이다.

테스트 데이터셋을 이용하여 확인한 제안한 방법과 다른 방법들의 정확도와 F1 스코어는 Table 3에 나타나 있다. 제안한 방법이 다른 방법들보다 누출 여부 및 누출의 크기를 잘 분류하는 것을 확인할 수 있다.

제안하는 방법과 다른 방법들의 성능 차이는 컨퓨전 매트릭스(Confusion Matrix)에서 좀 더 분명하게 드러난다(Fig. 4). 누출의 크기가 증가할 수록 타임-도메인에서 표현된 AE 신호의 강도가 증가하기 때문에 누출이 없는 정상 상태와 구분하기 쉽다(Fig. 1). 반대로 누출의 크기가 작은 경우 AE 신호의 강도가 크지 않으며 AE 센서가 노이즈에 취약하기 때문에 정상 상태와 구분하기 어렵다. 네 개의 CM들을 비교해 볼 때 제안하는 방법이 다른 방법들에 비해 누출이 없는 정상 상태인 레이블 0와 작은 크기의 누출이 있는 레이블 1을 좀 더 잘 구분하는 것을 확인할 수 있다.

가장 약한 크기의 누출인 2 l/min.의 경우 신호 강도가 크지 않아 정상 상태와 구분이 어렵기 때문에(Fig. 2) 제안한 방법과 다른 방법들 모두에서 잘못 예측하는 경우가 발생하는 것을 확인할 수 있다. 그렇지만 제안하는 방법과 다른 방법에 비하여 잘못 예측하는 경우가 더 적은 것을 확인할 수 있다.

제안하는 방법에서는 그레이 스케일로 정규화된 멜-스펙트로그램을 플라스마 컬러 코딩을 한 후 CNN 네트워크 모델의 입력으로 사용한다. 이는 검증된 CNN 모델의 구조를 최대한 바꾸지 않기 위한 목적도 있으나 그레이스케일 멜-스펙트로그램의 각 셀의 값의 차이를 더 잘 드러낼 수 있는 형태로 변환하는 효과도 있다. 그레이스케일 멜-스펙트로그램을 3개 채널로 쌓아 CNN 모델의 입력으로 사용한 경우와 플라스마 컬러 맵으로 코딩된 멜-스펙트로그램을 CNN의 입력으로 사용했을 때 플라스마 컬러 맵 코딩이 효과가 있다는 것을 실험적으로 확인할 수 있다(Table 4).

4. 결론 및 향후 과제

본 논문에서는 AE 센서를 이용하여 파이프라인에 발생하는 누출을 탐지하기 위한 방법을 제안한다. 제안하는 방법은 멜-스펙트로그램과 컬러 코딩을 통해 AE 신호를 이미지 형태로 전처리 한 다음 CNN에 입력하여 누출 및 누출의 강도를 분류할 수 있다. AE 신호를 이미지 형태로 전처리 하는 과정을 통하여 프리-트레이닝 된 공개 모델을 활용할 수 있다는 장점이 있다. 제안한 방법의 성능은 테스트베드에서 수집한 데이터를 사용하여 검증하였다. 제안한 방법은 누출 발생 및 누출의 강도를 탐지하는 것이 가능하며 강도가 약한 누출을 다른 방법들 보다 더 잘 탐지하는 것을 확인할 수 있다.

멜-스펙트로그램은 일반적인 이미지 보다 각 셀이 가지고 있을 수 있는 값의 범위가 넓다. 멜-스펙트로그램의 정규화와 컬러 코딩 과정에서 소실되는 정보가 존재할 수 있다. 향후 과제로는 정규화와 컬러 코딩 과정을 생략하고 멜-스펙트로그램을 직접 처리할 수 있는 CNN 구조를 설계하여 학습시키는 방향으로 연구를 진행할 계획이다.

ACKNOWLEDGEMENT

본 성과물은 중소벤처기업부에서 지원하는 2025년도 산학연 Collabo R&D사업(No. RS-2025-02310175)의 연구수행으로 인한 결과물임을 밝힙니다.

본 논문에서 사용된 데이터는 (주)리나솔루션에 의해 수집된 것임.

REFERENCES

1. Lee, M., Jeong, I., Chae, J., (2025), Machine learning-based classification of acoustic emission signals in SiC cathode ultrasonic machining process, *Journal of the Korean Society for Precision Engineering*, 42(6), 431-439.
2. Ohtsu, M., (2021), *Acoustic emission and related non-destructive evaluation techniques in the fracture mechanics of concrete*, Woodhead Publishing.
3. Sun, J., Wen, J., (2013), Target location method for pipeline pre-warning system based on HHT and time difference of arrival, *Measurement*, 46(8), 2716-2725.
4. Ahadi, M., Bakhtiar, M. S., (2010), Leak detection in water-filled plastic pipes through the application of tuned wavelet transforms to acoustic emission signals, *Applied Acoustics*, 71(7), 634-639.
5. Mandal, S. K., Chan, F. T., Tiwari, M., (2012), Leak detection of pipeline: An integrated approach of rough set theory and artificial bee colony trained SVM, *Expert Systems with Applications*, 39(3), 3071-3080.
6. Zhang, Y., Chen, S., Li, J., Jin, S., (2014), Leak detection monitoring system of long distance oil pipeline based on dynamic pressure transmitter, *Measurement*, 49, 382-389.
7. Xiao, R., Hu, Q., Li, J., (2019), Leak detection of gas pipelines using acoustic signals based on wavelet transform and support vector machine, *Measurement*, 146, 479-489.
8. Hu, X., Han, Y., Yu, B., Geng, Z., Fan, J., (2021), Novel leakage detection and water loss management of urban water supply network using multiscale neural networks, *Journal of Cleaner Production*, 278, 123611.
9. Zuo, Z., Ma, L., Liang, S., Liang, J., Zhang, H., Liu, T., (2022), A semi-supervised leakage detection method driven by multivariate time series for natural gas gathering pipeline, *Process Safety and Environmental Protection*, 164, 468-478.
10. Kopbayev, A., Khan, F., Yang, M., Halim, S. Z., (2022), Gas leakage detection using spatial and temporal neural network model, *Process Safety and Environmental Protection*, 160, 968-975.
11. Kim, H., Lee, J., Kim, T., Park, S. J., Kim, H., Jung, I. D., (2023), Advanced thermal fluid leakage detection system with machine learning algorithm for pipe-in-pipe structure, *Case Studies in Thermal Engineering*, 42, 102747.
12. Ahmad, Z., Nguyen, T.-K., Kim, J.-M., (2023), Leak detection and size identification in fluid pipelines using a novel vulnerability index and 1-D convolutional neural network, *Engineering Applications of Computational Fluid Mechanics*, 17(1), 2165159.
13. Logan, B., (2000), Mel frequency cepstral coefficients for music modeling, *Proceedings of the International Society for Music Information Retrieval Conference*.
14. Purohit, H., Tanabe, R., Ichige, K., Endo, T., Nikaido, Y., Suefusa, K., Kawaguchi, Y., (2019), MIMII dataset: Sound dataset for malfunctioning industrial machine investigation and inspection, *Proceedings of the Detection and Classification of Acoustic Scenes and Events Workshop*, 209-213.
15. He, K., Zhang, X., Ren, S., Sun, J., (2016), Deep residual learning for image recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778.
16. He, K., Zhang, X., Ren, S., Sun, J., (2016), Identity mappings in deep residual networks, *Proceedings of the European Conference on Computer Vision*, 630-645.
17. Park, J., Lee, S.-M., Lee, B.-J., Kim, S. J., Yoo, H.-M., (2023), Acoustic emission (AE) technology-based leak detection system using macro-fiber composite (MFC) sensor, *Composites Research*, 36(6), 429-434.
18. Loshchilov, I., Hutter, F., (2017), Decoupled weight decay regularization, *Proceedings of the International Conference on Learning Representations*.



Byungjae Park

BS, MS, and PhD degrees in POSTECH. He is currently an assistant professor at KOREATECH. His main research interests are robotic perception, machine learning, and sensor fusion.

E-mail: bjp@koreatech.ac.kr