

A Study on Leakage Detection Technique Using Transfer Learning-Based Feature Fusion

YuJin Han[†] · Tae-Jin Park^{††} · Jonghyuk Lee^{†††} · Ji-Hoon Bae^{†††}

ABSTRACT

When there were disparities in performance between models trained in the time and frequency domains, even after conducting an ensemble, we observed that the performance of the ensemble was compromised due to imbalances in the individual model performances. Therefore, this paper proposes a leakage detection technique to enhance the accuracy of pipeline leakage detection through a step-wise learning approach that extracts features from both the time and frequency domains and integrates them. This method involves a two-step learning process. In the Stage 1, independent model training is conducted in the time and frequency domains to effectively extract crucial features from the provided data in each domain. In Stage 2, the pre-trained models were utilized by removing their respective classifiers. Subsequently, the features from both domains were fused, and a new classifier was added for retraining. The proposed transfer learning-based feature fusion technique in this paper performs model training by integrating features extracted from the time and frequency domains. This integration exploits the complementary nature of features from both domains, allowing the model to leverage diverse information. As a result, it achieved a high accuracy of 99.88%, demonstrating outstanding performance in pipeline leakage detection.

Keywords : Pipe Leak Detection, Deep Learning, 1D CNN, Feature Fusion, Transfer Learning

전이학습 기반 특징융합을 이용한 누출판별 기법 연구

한 유진[†] · 박태진^{††} · 이종혁^{†††} · 배지훈^{†††}

요약

시간 및 주파수 영역에서 각각 학습한 모델 간에 성능 차이가 발생할 경우, 앙상블을 수행하더라도 개별 모델 간의 성능 불균형으로 인하여 앙상블의 성능이 오히려 저하되는 현상을 확인할 수 있었다. 따라서, 본 논문은 시간 영역과 주파수 영역에서 특징을 추출하고, 이들을 융합한 단계적 학습 방법을 통해 파이프라인 누출 감지의 정확성을 높이기 위한 누출판별 기법을 제안한다. 이 방법은 두 단계의 학습 과정으로 이루어지며, 먼저, 단계 1에서는 시간 영역과 주파수 영역에서 독립적으로 모델 학습을 수행하여 도메인별로 주어진 데이터로부터 중요한 특징들을 효과적으로 추출하도록 하였다. 단계 2에서는 사전학습 완료된 각 모델로부터 해당 분류기를 제거한 후, 두 도메인의 특징들을 서로 융합하고 새로운 분류기를 추가하여 재학습을 수행하였다. 본 논문에서 제안하는 전이학습 기반 특징융합 기법은 시간 및 주파수 영역에서 추출된 특징들을 융합하여 모델 학습을 수행함으로써, 두 영역의 특징이 상호 보완적으로 작용하여 모델이 다양한 정보를 활용함으로써 99.88%의 높은 정확도를 달성하여 파이프 누수 감지에 있어 우수한 성능을 입증하였다.

키워드 : 배관 누출 감지, 딥 러닝, 1D 합성곱 신경망, 특징융합, 전이학습

※ 이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. RS-2022-00165225).

※ 이 논문은 2023년도 한국정보기술학회의 우수논문으로 "플랜트 배관계 누출 판별을 위한 특징 융합 학습 기법"의 제목으로 발표된 논문을 확장한 것임.

† 준회원 : 대구가톨릭대학교 AI빅데이터공학과 석사과정

†† 비회원 : 한국원자력연구원 책임연구원

††† 정회원 : 대구가톨릭대학교 AI빅데이터공학과 조교수

Manuscript Received : July 24, 2023

First Revision : December 12, 2023

Second Revision : January 23, 2024

Accepted : January 23, 2024

* Corresponding Author : Ji-Hoon Bae(jihbae@cu.ac.kr)

1. 서론

최근, 원자력 발전소를 비롯한 발전 플랜트의 운영 기간이 증가하면서 초기에 설치되었던 배관이 부식되고 노후되고 있다. 부식과 노후화는 시간이 지남에 따라 배관의 누출 사례를 증가시키는 주된 원인이 되며[1,2], 이는 심각한 안전사고나 인명사고를 초래할 수 있는 위험성을 내포하고 있다. 이러한 사고들은 발전 플랜트의 안전성을 크게 위협하고, 결과적으로 경제적 손실과 환경오염을 초래할 수 있다. 따라서, 상기 문제

점들을 미연에 방지하고자 노후화된 배관계의 조기 누출 탐지는 발전소의 안전한 운영과 효과적인 유지보수를 위한 중요한 과제로 여겨지고 있다.

과거에는 배관의 누출을 탐지하기 위해 음향 센서나 진동 센서 등을 사용한 배관 누출 감지 기술이 활용되었다[3,4]. 하지만, 이러한 방법들은 배관의 위치와 상태에 따라 센서의 설치가 어렵고, 배관 내부에서 발생하는 누출을 정확하게 감지하기 어려운 한계를 갖고 있다. 이러한 한계점을 극복하기 위하여 보다 정확하고 신속한 누출 탐지가 가능한 새로운 접근 방식과 기술 도입이 필요한 실정이다.

최근에는 빅데이터 시대와 더불어 인공지능 분야, 특히 딥러닝 기술이 빠른 속도로 발전하고 있다[5]. 이러한 발전은 특히 제조업 분야에서 크게 주목받고 있으며, 생산성 향상과 제품 품질의 개선 및 설비 유지보수 효율성 증대 등 다양한 목적으로 활용되고 있다[6,7]. 인공지능 기술은 데이터를 기반으로 패턴을 학습하고 문제를 해결함으로써 높은 예측 정확성을 제공한다. 이는 제조업 분야에서 생산 과정을 최적화하고 효율적으로 운영할 수 있게 함으로써, 빠르게 변화하는 환경에서도 실시간 대응이 가능하다. 이러한 이점들은 제조업 분야에서 인공지능의 중요성을 더욱 부각시키고 있다[8,9].

이에 따라, 본 논문에서는 이러한 문제점을 해결하기 위하여, 음향 센서에서 수집한 시계열 데이터를 기반으로 시간 및 주파수 영역의 두 도메인을 고려한 인공지능 기반의 플랜트 미세 누출 탐지를 위한 전이학습[10,11] 기법을 적용한 특징 융합[12] 기법을 제안하고자 한다. 본 제안 방법은 기존 모델에서 학습된 지식을 사용하는 전이학습 접근법을 통하여 다양한 누출 패턴을 감지하는데 뛰어난 성능을 발휘할 수 있으며, 시간과 주파수 도메인에서 추출된 특징들을 융합함으로써 다양한 누출 패턴을 감지하고 이를 학습하여 누출판별 정확도를 향상시킬 수 있다.

2. 데이터 수집 환경 및 데이터 전처리

2.1 데이터 수집 환경

본 연구에서는 배관 누출 탐지를 위한 신호 처리와 데이터 분석 방법을 적용하여, 실제 작동 중인 배관에서 누출이 발생할 경우 위험을 최소화하면서 실제 환경을 반영하는 실험 환경을 구축하였다. 실제 환경에서 배관이 작동 중 누출되는 것은 위험할 수 있기 때문에 이를 안전하게 모방하기 위해 공기 압축기 장비와 함께 배관 시료를 사용하여 Fig. 1과 같은 배관계 환경의 누출발생 지점에서 누출을 의도적으로 발생시켜서 누출 데이터를 수집하였다.

각 채널 당 샘플링 주파수는 100 KHz로 설정하였고, 누출 신호의 측정 시간은 5초로 설정하였으며, 누출 데이터 획득을 위하여 4개의 마이크로폰 음향 센서를 사용하였다. 누출 배관은 총 8군데 위치에서 측정되었으며, 미세 누출 탐지 기준을 고려하여[13] 누출 압력은 1~2 bar 압력을 가변하면서 누출부




Fig. 1. Data Collection Environment

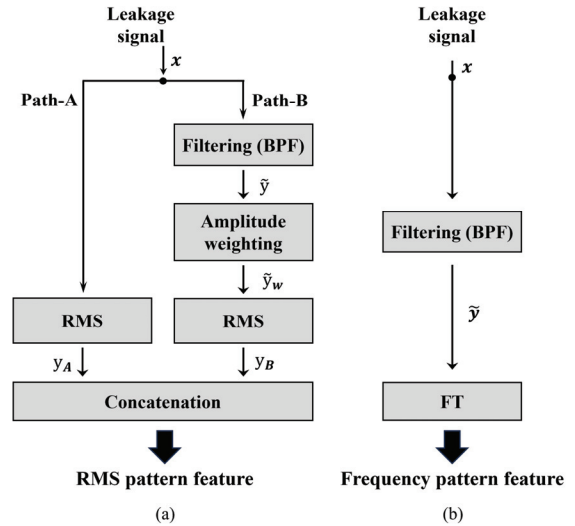


Fig. 2. Data Preprocessing Structure for RMS and Frequency Pattern Feature Extraction

직경은 0.5mm 크기로 설정하였으며, 각 센서로부터 500,000 개의 데이터를 수집하였다.

2.2 데이터 전처리

본 연구에서는 Fig. 2와 같이 마이크로폰 센서로부터 수신된 시계열 음향 신호 x 로부터 인공지능 모델 학습에 적합한 데이터 전처리를 수행하기 위하여, 1차원 시계열 신호로부터 크기 정보를 나타내는 RMS(root mean square) 패턴 특징을 추출한다. 또한, 시간 영역과 대응되는 주파수 영역에서 주파수 패턴 특징을 추출한다. 여기서, RMS 패턴 특징을 추출하기 위하여 Fig. 2(a)와 같이 두 가지 신호 처리 경로 Path-A와 Path-B를 사용한다. 먼저, Fig. 2(a)의 Path-A에서는 Ts 간격으로 샘플링된 $x = [x_n]$ 에 대하여 Equation (1)로부터 RMS 레벨을 직접 계산하여 $y_A = [y_n]_{n=1,2,\dots,T}$ 를 생성한다.

$$y_n = \frac{1}{A_m} \left\{ \sum_{i=0}^{N_s-1} x_{n+i}^2 \right\}^{1/2}, n = 1, 2, \dots, T, \quad (1)$$

여기서, A_m 는 정규화 계수를, N_s 는 수신 데이터의 제공근을 평균화하는데 사용되는 윈도우 크기를 각각 의미한다.

Path-B에서는 band-pass filter(BPF) 블록을 통해 누출 신호가 분포하는 특정 대역만을 통과시키고 다른 신호는 차단하

여 BPF를 통과한 \tilde{y} 를 출력한다. 이후, 진폭 가중치(Amplitude weighting) 블록에서 \tilde{y} 의 주파수 영역 스펙트럼에 가중치 함수 $W(f)$ 를 적용하여, Equation (2)와 같이 필터 통과 대역의 특정 신호를 강조하도록 \tilde{y}_w 를 생성한다.

$$\tilde{y}_w = IFT \{ W(f) \cdot FT\{\tilde{y}\} \}, \quad (2)$$

여기서, $FT\{\cdot\}$ 와 $IFT\{\cdot\}$ 는 각각 1차원 푸리에 변환(FT)과 1차원 역 푸리에 변환(IFT)을 의미하며, $\tilde{y} = BPF\{x\}$ 으로 정의된다. Path-A와 마찬가지로, \tilde{y}_w 에 대한 RMS 레벨을 계산하여 y_B 를 생성한 후, Equation (3)과 같이 두 경로의 y_A 벡터와 y_B 벡터를 결합한 RMS 패턴 최종 특징을 생성한다.


$$y_{rms} = [y_A, y_B] \quad (3)$$

따라서, Path-B에서는 BPF 블록과 진폭 가중치 블록을 적용하여 누출 신호가 분포하는 특정 대역을 통과시키고, 외부 잡음을 줄이기 위하여 해당 스펙트럼이 집중적으로 존재하는 신호를 증폭시켜서 누출 신호를 강조하도록 한다.


다음으로, 누출 신호에 대한 주파수 응답 스펙트럼 크기를 반영한 특징 생성을 위하여, 수신된 시계열 데이터로부터 주파수 패턴 특징을 추출하기 위한 방법은 Fig. 2(b)와 같이 주어진다. Fig. 2(a)의 Path-B와 마찬가지로 RMS 패턴 특징 추출에 입력된 동일한 시계열 신호를 BPF 블록에 입력하여 특정 대역을 통과한 \tilde{y} 를 출력한 후, 1차원 FT(one-dimensional Fourier Transform)를 사용하여 주파수 영역 데이터로 변환된 주파수 패턴 특징인 $|FT\{\tilde{y}\}|$ 을 최종 생성한다.

Fig. 3은 Fig. 2(a)를 통해 생성된 RMS 패턴 특징을 나타낸다. Fig. 3의 x축 samples에서 중심을 기준으로 왼쪽은 Path-A에서 필터링 없이 직접적으로 RMS 레벨을 계산한 구간이며, 오른쪽은 Path-B에서 필터링 및 진폭 가중치를 적용한 후 RMS 레벨을 계산한 구간이다. Fig. 3(a)와 같이 누출 신호는 필터링 후 가중치가 적용되어 Path-B인 오른쪽 구간에서 RMS 패턴이 상승하는 경향을 보여준다. 반면에, 잡음 신호는 Fig. 3(b)와 같이 필터링 블록에 의해 외부 잡음이 차단되고, 상기 차단된 미약신호에 가중치가 적용되더라도 RMS 패턴 크기가 상승하지 않아 오히려 Path-B인 오른쪽 구간에서 패턴이 하강하는 경향을 관찰할 수 있다.

Fig. 4는 누출 및 잡음 신호 각각에 Fig. 2(b)에 도시된 데이터 전처리 방법을 적용하여 생성된 주파수 패턴 특징들을 보여준다. Fig. 4를 살펴보면, BPF 필터링을 통하여 생성된 누출 신호의 스펙트럼 크기와 패턴 모양이 잡음 신호 스펙트럼과 차이가 발생하는 것을 확인할 수 있다. 따라서, Fig. 2에서 제시한 데이터 전처리를 통해 본 연구에서 제안한 모델 학습 시, 누출 및 잡음 신호에 대하여 누출판별 정확도 관점에서 더 향상된 패턴 구분이 가능하도록 한다.




(a) Leak Signal




(b) Noise Signal

Fig. 3. RMS Pattern Features



(a) Leak Signal



(b) Noise Signal

Fig. 4. Frequency Pattern Features

3. 전이학습 기반 특징융합 기법

본 연구에서는 시간 영역과 주파수 영역에서 전처리 된 두 도메인 신호들의 특징을 융합하여 분류하는 전이학습 기반의 특징융합 기법을 제안한다. 각 도메인별로 RMS 패턴 및 주파수 패턴 특징 데이터를 활용하여 1차원 CNN(1-Dimensional Convolutional Neural Network) 모델을 학습한 뒤, 각 모델에서 분류기를 제외한 CNN 출력 특징들을 결합하고, 이후에 새로운 분류기를 추가하고 재학습을 수행하여 누출과 정상을 더욱 정확하게 분류할 수 있도록 단계적 학습을 진행하였다.

먼저, Fig. 5의 단계 1(Stage 1)은 1차원 합성곱 층(convolutional layer)[14,15]과 최대값 풀링 층(max pooling layer) [16]을 기반으로 하는 딥러닝 모델을 설계하여 시간 영역에서의

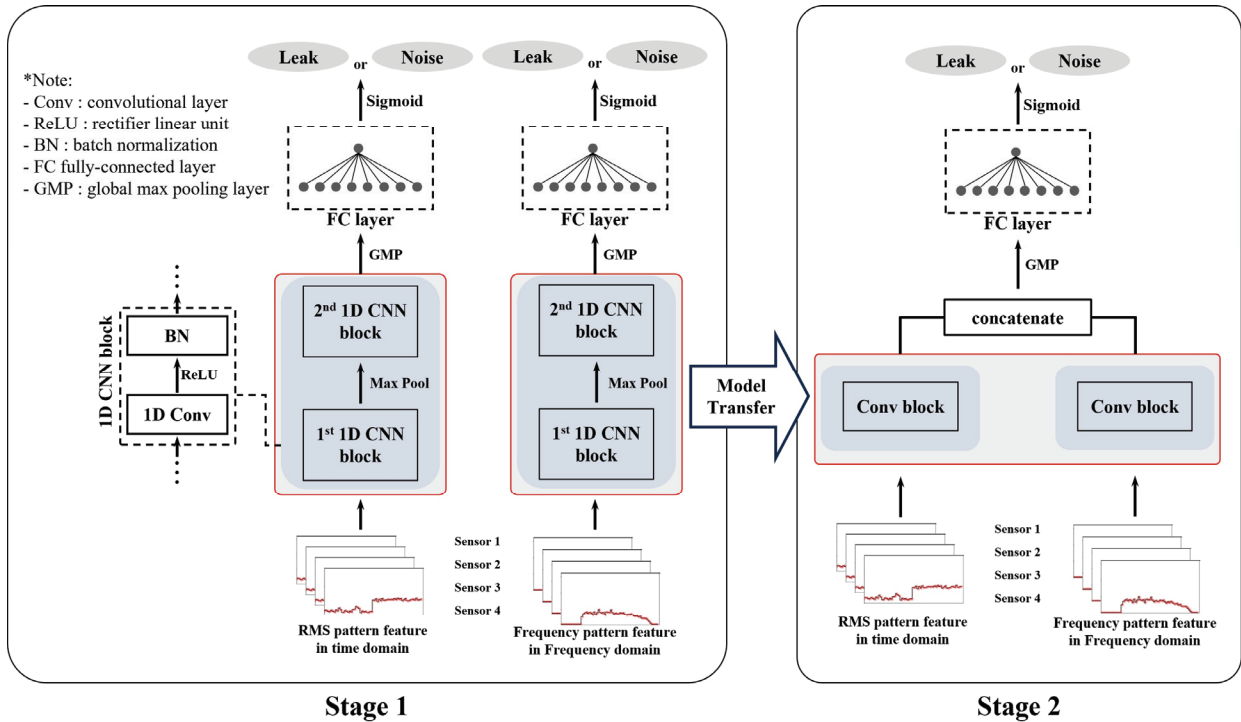


Fig. 5. Structure of the Leak Detection Feature Fusion Model Using Transfer Learning

합성곱 출력 특징을 추출하도록 모델 학습을 수행한다. 첫 번째 1차원 합성곱 층은 3×3 커널 필터를 적용하여 16개의 1차원 특징맵을 추출하고, 두 번째 1차원 합성곱 층 또한 동일한 3×3 커널 필터를 적용하여 32개의 1차원 특징맵을 추출한다. 이때, 1차원 합성곱 층의 활성화 함수로는 ReLU(rectified linear unit)를 적용하였으며, 과대 적합을 방지하면서 학습 과정의 안정성을 높이기 위하여 배치 정규화(batch normalization) [17]를 추가하였다. 또한, 최대값 풀링 층을 합성곱 층 사이에 추가하여 CNN 모델 구조의 복잡도를 점진적으로 줄이도록 한다. 이후, GMP(global max pooling)[18] 층을 도입하여 마지막 합성곱 층에서 출력되는 특징맵에서 대푯값으로 최대 값을 추출하고, 이를 통해 최종적으로 1차원 특징 벡터를 생성하도록 한다. 마지막으로, 생성된 1차원 특징 벡터를 완전 연결 층(fully-connected layer)에 입력하여 누출 신호와 정상 신호를 분류하였다. 이때, 완전 연결 층은 1개의 출력 뉴런을 가지고 있으며, 시그모이드(Sigmoid) 활성화 함수를 사용한다.

주파수 영역에서도 시간 영역과 동일한 1차원 CNN 모델 구조에 시계열 데이터로부터 Fig. 2(b)의 데이터 전처리 알고리즘에 의해 생성된 주파수 패턴 특징 데이터들을 입력하여 모델 학습을 진행한다. 따라서, Fig. 5의 단계 1과 같이 두 도메인의 모델을 개별적으로 학습한 후, 학습이 완료되면 각 모델에서 해당 분류기를 제거한 후 Fig. 5의 단계 2(Stage 2)로 모델 이전을 수행한다.

Fig. 5의 단계 2에서는 concatenate[19] 층을 채택하여 단계 1에서 추출된 두 도메인의 특징들을 결합한다. 이를 통해

두 도메인에서 각각 사전에 학습된 모델의 가중치와 구조를 융합하여 단계 2의 모델 학습에 효과적으로 활용할 수 있도록 한다. 마지막으로, 결합된 특징 벡터를 입력으로 받아 새로운 분류기를 추가하고, 이를 통해 누출과 정상을 분류하도록 학습하여 각 클래스에 대한 확률을 출력하도록 한다. 이러한 전이학습 기반의 특징융합 기법은 시간 영역과 주파수 영역의 특징들을 효과적으로 결합하고 융합된 특징에 대한 학습을 수행함으로써 배관의 누출 상태를 정확하게 탐지할 수 있도록 한다.

4. 실험 결과

본 논문에서는 특징융합 학습 기법을 위한 사전 작업으로, 단계 1에서 시간 영역과 주파수 영역의 특징들을 추출하기 위한 1D CNN 모델을 각각 학습하였다. 다음으로, 학습된 모델에 대한 전이학습을 통하여 두 영역의 특징들을 서로 융합하는 단계 2 학습을 진행하였다. 제안된 모델의 누출판별 성능을 평가하기 위해 시간 영역과 주파수 영역의 데이터 세트를 8:2의 비율로 훈련 세트와 테스트 세트로 분할하여 구성하였다. 이후, 훈련 세트는 다시 8:2의 비율로 부분 훈련 세트와 검증 세트로 분할하여 모델 학습에 사용하였다. 또한, 모델 학습을 위해 배치 사이즈(Batch Size)는 128, 에포크(Epoch)는 40으로 설정하고, 학습 알고리즘으로 SGD(Stochastic Gradient Descent)[20]를 채택하였으며, 학습률(learning rate)은 0.001로 설정하였다.

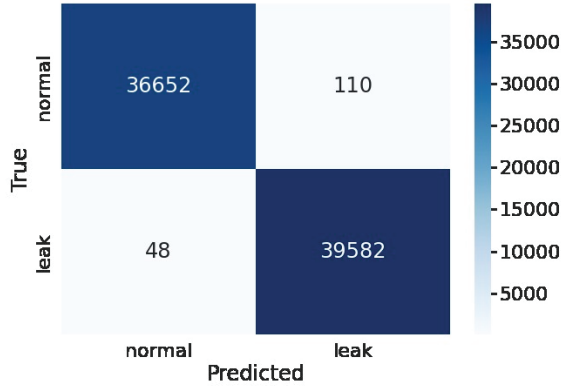


Fig. 6. Confusion Matrix of Transfer Learning-based Feature Fusion Models

Table 1. Comparison of accuracy performance

No	Model	Accuracy (%)	Rank
1	1D CNN using RMS feature	93.38	5
2	1D CNN using Frequency feature	98.48	3
3	Ensemble method	97.09	4
4	Feature Fusion method	99.53	2
5	Transfer learning-based feature fusion	99.88	1

Table 2. Leak Detection Performance Comparison Using Classification Performance Metrics

No	Model	Precision	Recall	F1 score
1	1D CNN using RMS feature	0.9243	0.9468	0.9354
2	1D CNN using Frequency feature	0.9952	0.9788	0.9869
3	Ensemble method	0.9758	0.9686	0.9722
4	Feature Fusion method	0.9972	0.9988	0.9980
5	Transfer learning-based feature fusion	0.9992	0.9990	0.9991

제안 모델(No. #5)과의 성능 비교를 위하여, Table 1의 No. #1 모델과 No. #2 모델은 시간 및 주파수 영역에서 3장에서 기술한 단계 1의 1D CNN 기반 단일 모델 구조와 각각 동일한 구조를 가진다. No. #3 모델은 No. #1 모델과 No. #2 모델의 각 도메인에서의 최종 출력을 동일한 가중치로 평균한 앙상블 모델 구조를 가지도록 구성하였다. 마지막으로, No. #4 모델은 Fig. 5에서 단계 1에서 학습한 모델을 단계 2로 이전하는 과정 없이 단계 2만 적용하여 시간 및 주파수 영역의 두 도메인을 전이학습 없이 엔드-투-엔드(end-to-end) 방식으로 특징을 융합하여 학습한 구조를 가진다. Table 1에 기재된 각 방법에 대한 정확도는 총 5번의 실험 중에서 가장 높은 결과 값 3개를 선택하여 평균을 계산한 결과이다.

Table 1의 실험 결과와 같이 일반적으로, 단일 모델(No.

#1, No. #2)의 학습 결과보다는 앙상블[21,22] 방법이 여러 모델의 예측 결과를 종합하기 때문에 상위 성능을 발휘한다. 하지만, Table 1의 No. #3 모델에 대한 결과를 살펴보면, 시간 및 주파수 영역에서 각각 학습한 No. #1 모델과 No. #2 모델 간에 성능 차이가 발생할 경우, 앙상블을 수행하더라도 개별 모델 간의 성능 불균형으로 인하여 앙상블의 성능이 오히려 저하되는 현상을 확인할 수 있었다.

이러한 문제점을 해결하기 위하여, 본 논문에서는 전이학습 기반의 특징융합 기법을 적용한 단계적 학습 방법을 통해 개별 모델 간의 성능 불균형으로 인한 성능 저하를 방지할 수 있도록 하였다. 즉, 본 연구의 시간 및 주파수 영역에서 추출된 특징들을 융합하여 모델 학습을 수행함으로써, 두 영역의 특징이 상호 보완적으로 작용할 수 있고, 이를 통해 모델이 다양한 정보를 활용하여 성능이 개선될 수 있다. Table 1의 결과에서와 같이, 특징융합 기법(No. #4)이 앙상블 기법(No. #3)보다 누출판별 정확도가 2.79% 향상된 것을 확인할 수 있다.

Fig. 6은 Table 1의 전이학습 기반 특징융합 기법(No. #5)을 활용하여 모델의 성능을 혼동행렬(Confusion matrix)로 나타낸 것이며, Table 2는 Table 1의 결과를 바탕으로 혼동행렬에 따른 평가 지표들을 비교한 결과를 기재한 것이다. 여기서, 정밀도(Precision)는 다음 Equation (4)와 같이 정의되며, 실제 Positive인 사례 중 모델이 Positive로 예측한 사례의 비율로 계산된다.

$$Precision = \frac{TP}{TP+FP} \tag{4}$$

이는 모델이 Positive로 예측한 것 중에서 실제로 Positive인 경우를 나타낸다.

재현율(Recall)은 실제 Positive인 사례 중에서 모델이 Positive로 정확히 예측한 사례의 비율을 나타내며, 다음 Equation (5)와 같이 계산된다.

$$Recall = \frac{TP}{TP+FN} \tag{5}$$

또한, F1 점수(F1 Score)는 정밀도와 재현율의 조화평균으로 계산되며, 정밀도와 재현율이 어느 정도 균형을 이룰 때 높은 값을 갖는다. F1 점수는 다음 Equation (6)과 같이 계산된다.

$$F1\ Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \tag{6}$$

Table 2를 관찰해보면, 본 논문에서 제안하는 전이학습 기반 특징융합 학습 모델(No. #5)이 정밀도 0.9992, 재현율 0.9990, F1 점수 0.9991로 다른 누출 탐지 모델들보다 누출 신호 탐지에 있어 보다 우수한 성능을 보여주는 것을 실험적으로 관찰할 수 있었다.

이를 통하여 시간 영역과 주파수 영역의 성능을 최대한 활용하면서, 융합된 특징에 대한 자동 학습을 통하여 모델 간의 성능 차이 문제를 극복하고, 누출판별 성능을 크게 향상시킬 수 있음을 확인하였다. 그 결과, Fig. 6과 같이 전반적으로 모델의 예측 성능이 좋은 결과를 보였으며, 약 99.88%의 높은 정확도 성능을 보여주는 것을 실험적으로 관찰할 수 있었다.

따라서, 1D CNN을 활용한 특징융합 학습 방법, 기존의 앙상블 방법, 기존 특징융합 방법 그리고 전이학습을 적용한 특징융합 방법을 비교 분석한 결과, 본 논문에서 제안하는 전이 학습 기반의 특징융합 기법이 가장 우수한 성능을 보임을 실험적으로 확인하였다. 이는 전이학습 기반으로 두 도메인의 특징을 융합하여 학습함으로써 두 영역 간의 성능 차이를 해결하고, 각 영역의 특징을 보다 효과적으로 학습하여 누출판별 성능을 크게 향상시키는 데에 중요한 역할을 수행하였음을 입증한다.

5. 결 론

본 논문에서 제시한 접근법은 시간 영역과 주파수 영역에서 특징을 추출하고, 이들을 융합한 단계적 학습 방법을 통해 파이프라인 누출 감지의 정확성을 높이기 위한 누출판별 기법을 제안하였다. 이를 위하여, 먼저, Stage 1에서는 시간 영역과 주파수 영역에서 독립적으로 모델 학습을 수행하여 도메인 별로 주어진 데이터로부터 중요한 특징들을 효과적으로 추출하도록 하였다. 다음의 Stage 2에서는 사전학습 완료된 각 모델로부터 해당 분류기를 제거한 후, 두 도메인의 특징들을 서로 융합하여 복합적인 특징을 반영할 수 있는 새로운 모델 학습을 수행하였다. 이러한 두 도메인에서의 전이학습 기반 융합 지식을 활용하게 되면, 기존 앙상블 기법뿐만 아니라 전이 학습이 적용되지 않은 특징융합 모델보다 더 정확한 누출판별 성능을 제공할 수 있음을 실험적으로 입증할 수 있었다.

결론적으로, 본 논문에서 제안한 전이학습 기반의 특징융합 기법을 적용한 단계적 학습 방법을 통하여 파이프라인 누출 탐지뿐만 아니라 다양한 도메인에서의 문제 해결에도 응용될 수 있을 것으로 기대되며, 향후 연구에서는 새로운 분류기를 도입하여 전이학습 기반의 특징융합 기법을 강화하고, 이를 Attention 메커니즘과 함께 조합하여 다양한 도메인 데이터에 적용하여 효과를 더욱 검증하고자 한다.

References

- [1] R. Puust, Z. Kapelan, D. Savic, and T. Koppel, "A review of methods for leakage management in pipe networks," *Urban Water Journal*, Vol.7, No.1, pp.25-45, 2010.
- [2] H. Vanaei, A. Eslami, and A. Egbewande, "A review on pipeline corrosion, in-line inspection (ili), and corrosion growth rate models," *International Journal of Pressure Vessels and Piping*, Vol.149, pp.43-54, 2017.
- [3] M.-S. Kim and S.-K. Lee, "Detection of leak acoustic signal in buried gas pipe based on the time-frequency analysis," *Journal of Loss Prevention in the Process Industries*, Vol. 22, No.6, pp.990-994, 2009.
- [4] D. B. Yoon, S. S. Moon, and B. S. Yang, "A study on acoustic signal processing method for detecting small leak of piping system," *Proc. of the Domestic conference on the Korean Society for Noise and Vibration Engineering*, Hoengseong, Korea, pp.139-139, 2016.
- [5] Y. Duan, J. S. Edwards, and Y. K. Dwivedi, "Artificial intelligence for decision making in the era of big data-evolution, challenges and research agenda," *International Journal of Information Management*, Vol.48, pp.63-71, 2019.
- [6] Z. Wang, J. Zhang, X. Li, and X. Liu, "Deep learning for smart manufacturing: Methods and applications," *IEEE Transactions on Industrial Informatics*, Vol.14, No.12, pp.5328-5338, 2018.
- [7] J. F. Arinez, Q. Chang, R. X. Gao, C. Xu, and J. Zhang, "Artificial intelligence in advanced manufacturing: Current status and future outlook," *Journal of Manufacturing Science and Engineering*, Vol.142, No.11, pp.110804, 2020.
- [8] D. Yeo, J.-H. Bae, and J.-C. Lee, "Unsupervised learning-based pipe leak detection using deep auto-encoder," *Journal of The Korea Society of Computer and Information*, Vol.24, No.9, pp.21-27, 2019. <https://doi.org/10.9708/jksci.2019.24.09.021>.
- [9] J. S. Park, D. Yeo, Y. Choi, J. Lee, and J.-H. Bae, "Implementation of a deep-learning model for intelligent detection of low-level leaks in plant piping system," *Proceeding of KIIT Conference*, Jeju, Korea, pp.431-435, 2021.
- [10] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, "How transferable are features in deep neural networks?," *Advances in Neural Information Processing Systems*, pp.3320-3328, 2014.
- [11] S. J. Pan and Q. Yang, "A survey on transfer learning," *IEEE Transactions on Knowledge and Data Engineering*, Vol.22, No.10, pp.1345-1359, 2010.
- [12] Y. Dai, F. Gieseke, S. Oehmcke, Y. Wu, and K. Barnard, "Attentional feature fusion," in *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, pp.3560-3569, 2021.
- [13] Y. Choi, J. Lee, and J. Cho, "A technology of micro-leak detection," *Proceedings of the Korean Society of Computer Information Conference*, Vol.29, No.2, pp.685-687, 2021.

[14] Yoon Kim, "Convolutional Neural Networks for Sentence Classification," *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp.1746-1751, 2014.

[15] Y. Wang, C. Yan, T. Oates, and D. Li, "Time series classification from scratch with deep neural networks: A strong baseline," *Journal of Systems Science and Complexity*, Vol.30, No.3, pp.686-701, 2017.

[16] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-Based Learning Applied to Document Recognition," *Proceedings of the IEEE*, Vol.86, No.11, pp.2278-2324, 1998.

[17] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," *Proceedings of the 32nd International Conference on Machine Learning*, Vol.37, pp.448-456, 2015.

[18] B. Zhou, A. Khosla, A. Lapedriza, A. Oliva, and A. Torralba, "Learning deep features for discriminative localization," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.2921-2929, 2016.

[19] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.4700-4708, 2017.

[20] L. Bottou, "Stochastic Gradient Descent Tricks," in *Neural Networks: Tricks of the Trade*, 2nd ed., G. Montavon, G. Orr, and K.-R. Müller, Eds. Berlin, Germany: Springer, pp.421-436, 2012.

[21] L. Breiman, "Bagging and boosting," in *Proceedings of the Fourteenth National Conference on Artificial Intelligence and Ninth Conference on Innovative Applications of Artificial Intelligence*, Vol.1, No.1, pp.799-806, 1996.

[22] M. A. Ganaie, M. Hu, A. Malik, M. Tanveer, and P. Suganthan, "En-semble deep learning: A review," *Engineering Applications of Artificial Intelligence*, Vol.115, pp.105151, 2022.



한 유 진

https://orcid.org/0009-0007-2942-9643
 e-mail : yuzn515@cu.ac.kr
 2022년 대구가톨릭대학교
 인공지능·빅데이터공학과(학사)
 2022년 ~ 현 재 대구가톨릭대학교
 AI빅데이터공학과 석사과정

관심분야 : Deep Learning, Continual Learning, Reinforcement Learning, Signal Processing



박 태 진


https://orcid.org/0000-0001-9057-9201
 e-mail : etjpark@kaeri.re.kr
 1997년 연세대학교 화학과(학사)
 1999년 연세대학교 화학과(석사)
 2001년 한국과학기술원(KIST) 연구과학자

2007년 The State University of New York at Stony Brook (SUNY Stony Brook) (Ph.D)

2007년 ~ 2011년 University of California at Davis (UC Davis) (Postdoc)

2011년 ~ 현 재 한국원자력연구원 책임연구원

관심분야 : Wireless Technology Application in Smart Sensing and Diagnosis for Instrumentations in Nuclear Power Plants, Radwastes Disposal Safety, Thermochemistry, Nano and Materials Sciences relevant to Nuclear Energy



이 종 혁

https://orcid.org/0000-0002-8163-9388
 e-mail : jonghyuk@cu.ac.kr
 2004년 고려대학교 컴퓨터교육학과(학사)
 2006년 고려대학교 컴퓨터교육학과(석사)
 2011년 고려대학교 컴퓨터교육학과(박사)
 2011년 ~ 2012년 University of Houston
 Post-Doc. 연구원

2012년 ~ 2017년 삼성전자 책임연구원

2017년 ~ 현 재 대구가톨릭대학교 AI빅데이터공학과 조교수

관심분야 : Cloud Computing, Big Data, Artificial Intelligence



배 지 훈

https://orcid.org/0000-0002-0035-5261
 e-mail : jihbae@cu.ac.kr
 2000년 경북대학교 전자·전기공학부(학사)
 2002년 포항공과대학교 전자컴퓨터공학부 (석사)
 2016년 포항공과대학교 전자·전기공학부 (박사)

2002년 ~ 2019년 한국전자통신연구원 책임연구원

2019년 ~ 현 재 대구가톨릭대학교 AI빅데이터공학과 조교수

2021년 ~ 현 재 대구가톨릭대학교 SW중심대학사업단 SW 기초교육센터장

관심분야 : Artificial Intelligence, Deep Learning/Machine Learning, Radar Imaging, Signal Processing, Optimization Techniques