

다중모드 특징융합 기반 배관계 누출판별 앙상블 모델 연구

권성수*¹, 전서영*², 최유락**¹, 이종혁***¹, 배지훈***²

Study on an Ensemble Model for Pipe Leak Detection based on Multi-mode Feature Fusion

Sungsoo Kwon*¹, Seoyoung Jeon*², Yurak Choi**¹, Jonghyuk Lee***¹, and Ji-Hoon Bae***²

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

요약

본 논문은 플랜트 배관계의 노후화 문제로 인해 발생하는 미세 누출을 탐지하기 위한 다중모드 특징융합을 이용한 가중치 재분배 앙상블 모델을 제안한다. 수집된 데이터는 2D 주파수 패턴 특징과 2D RMS 패턴 특징으로 변환되었으며, 여러 센서에서 추출된 다양한 도메인 특징들이 서로 결합되어 볼륨 특징으로 구성하였다. 실험을 위해 ResNet 기반의 단일 모델을 설계하여 다양한 볼륨 특징들을 이용한 앙상블 구조를 조합하였다. 또한, 다수의 예측 모델을 결합하는 과정에서 발생할 수 있는 성능 불균형 문제를 해결하기 위해, 소프트맥스 함수를 기반으로 한 가중치 재분배를 적용하였다. 실험 결과, 주파수 및 RMS 볼륨 특징을 활용한 센서별 앙상블 모델이 98.91%라는 가장 높은 분류 정확도를 제공하는 것을 실험적으로 관찰할 수 있었다.

Abstract

This paper proposes a weight redistribution ensemble model using multi-mode feature fusion for detecting micro leaks arising from aging problems in the power plant piping systems. The collected data was transformed into 2D frequency and RMS pattern features, and various domain features extracted from multiple sensors were combined to form volume features. For the experiment, a single model based on ResNet was designed, and an ensemble structure using various volume features was composed. Additionally, in order to resolve the performance imbalance problem that could arise in the process of combining multiple predictive models, we applied a softmax function-based weight redistribution. Experimental results showed that the ensemble model for each sensor, using frequency and RMS volume features, provided the highest classification accuracy of 98.91%.

Keywords

deep learning, multi-mode feature fusion, ensemble, pipe leak detection, weight redistribution

* 대구가톨릭대학교 AI빅데이터공학과
- ORCID¹: <https://orcid.org/0009-0004-9623-0878>
- ORCID²: <https://orcid.org/0009-0000-7093-3217>
** 한국원자력연구원 책임연구원
- ORCID: <https://orcid.org/0000-0002-7868-257X>
*** 대구가톨릭대학교 AI빅데이터공학과 조교수
(***² 교신저자)
- ORCID¹: <http://orcid.org/0000-0002-8163-9388>
- ORCID²: <http://orcid.org/0000-0002-0035-5261>

• Received: Jul. 10, 2023, Revised: Jul. 20, 2023, Accepted: Jul. 27, 2023
• Corresponding Author: Ji-Hoon Bae
Dept. of AI and Big Data Engineering, Hayang-ro 13-13, Hayang-eup,
Gyeongsan-si, Gyeongsangbuk-do, Korea
Tel.: +82-53-850-2883, Email: jihbae@cu.ac.kr

1. 서 론

원자력 발전소를 비롯한 발전 플랜트의 가동년수 증가로 배관계 노후화가 가속화되고 있어, 배관 누출 사고의 발생 가능성이 커지고 있다. 이러한 배관 시스템의 노후화는 끊임없는 신뢰성과 안전성에 대한 우려를 불러일으키며, 가장 우려되는 문제 중 하나는 배관 누출이다. 배관의 미세한 누출은 시간이 경과함에 따라 점차 악화하여 심각한 누출 상황으로 이어질 수 있으며, 이에 따라 인명 피해, 경제적 손실, 심지어는 심각한 환경 오염 위험을 초래할 수 있다. 이와 같은 이유로 노후화된 배관계의 누출 감지는 국가적인 안전과 환경 보호의 중요한 과제로 떠오르고 있다. 과거에는 누출 문제를 해결하기 위해 음향 센서나 진동 센서 등을 사용한 배관 누출 감지 방법이 활용되었다[1][2]. 하지만, 이러한 기존 방식은 기계의 잡음이나 주변의 소음 환경으로 인해 미세한 누출을 판별하는 데에 한계가 있다.

최근에는 인공지능과 빅데이터 시대가 도래함에 따라, 딥러닝과 같은 첨단 기술이 빠르게 발전하고 있다. 이러한 발전은 다양한 문제 해결의 새로운 가능성을 제시하며, 산업 분야에서 생산성과 효율성의 향상을 이끌어 내고 있다. 특히, 노후 배관의 누출 감지 분야에서는 인공지능 기술 적용의 가능성이 크게 늘어나고 있다[3][4].

본 논문에서는 음향 센서로부터 수집된 데이터를 Two-Dimensional(2D) 패턴 특징으로 변환하고, 이러한 패턴 특징들을 활용하여 다양한 볼륨 특징들로 구성하여 플랜트 배관계에서의 미세 누출을 탐지하기 위한 다중모드 특징융합을 이용한 가중치 재분배 앙상블 모델을 제안하고자 한다.

본 논문의 2장에서는 학습을 위한 데이터 수집과 전처리 방법에 대한 설명을 한다. 3장에서는 누출판별을 위한 가중치 재분배 앙상블 모델 실험 방법에 대하여 설명한다. 4장에서는 모델에 대한 성능 결과와 분석을 수행한다. 마지막 5장에서는 본 논문의 결론 및 향후 연구에 관하여 기술한다.

II. 데이터 수집 및 전처리

2.1 데이터 수집 및 전처리

본 연구는 그림 1과 같은 환경에서 4개의 마이크로폰 센서를 활용하여 100kHz의 샘플링 주파수로 5초 동안 딥러닝 모델 학습에 필요한 총 500,000개의 채널별 데이터를 수집하였다. 이때, 미세 누출 탐지 기준을 고려하여[5], 배치된 배관에 0.5mm 누출부 직경을 가지는 여덟 군데 위치에서 1~2bar 압력을 가변하여 측정된 미세 누출 신호를 포함한 다양한 누출 신호들을 측정하여 데이터들을 수집하였다.

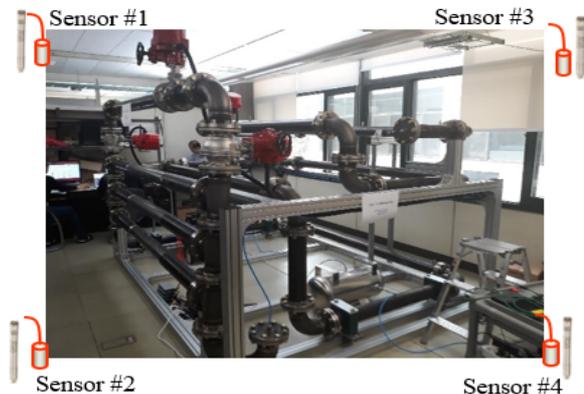
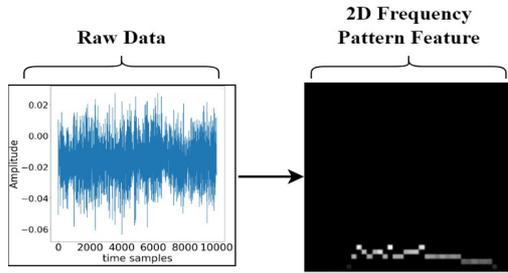


그림 1. 데이터 수집 환경

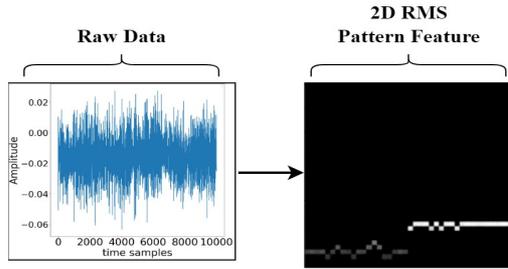
Fig. 1. Experimental setup for data collection

수집된 데이터는 [6]에서 활용한 데이터 전처리 기법을 적용하여, 그림 2에서 보여지는 바와 같이, 시계열 데이터를 2D 주파수 패턴 특징과 2D RMS 패턴 특징으로 변환하였다. 2D 주파수 패턴 특징은 누출 신호의 주파수 응답 크기를 고려한 것으로, 시간에 따른 음향 데이터를 푸리에 변환을 통해 주파수 영역 데이터로 변환하였다. 2D RMS 패턴 특징은 누출 신호의 진폭 변화를 기반으로 한 것으로, 해당 신호의 RMS 값을 계산하여 이를 이미지로 변환하였다. 또한, 다수의 센서로부터 추출된 도메인 특징들을 서로 결합하여 학습하기 위해 그림 3과 같은 다중모드 볼륨 특징들을 구성하였다. 그림 3의 Case 1과 Case 2는 각각 2D 주파수 패턴 특징과 RMS 패턴 특징을 깊이 방향으로 4개의 센서를 순서대로 결합한 예시이다. Case 3은 2D 주파수 패턴 특징과 RMS 패턴 특징을 깊이 방향으로 서로 결합한 예시이다. 그림 3과 같이 구성된 다중모드 볼륨 특징은 각각의 센서에서 얻어진 정보를 결합하여 누출 판별 학습을 위한 특징 데이터로 활용한다.



(a) 2D 주파수 패턴 특징

(a) 2D Frequency pattern feature



(b) 2D RMS 패턴 특징

(b) 2D RMS Pattern Feature

그림 2. 2D 주파수 및 RMS 패턴 특징

Fig. 2. 2D frequency and RMS pattern feature

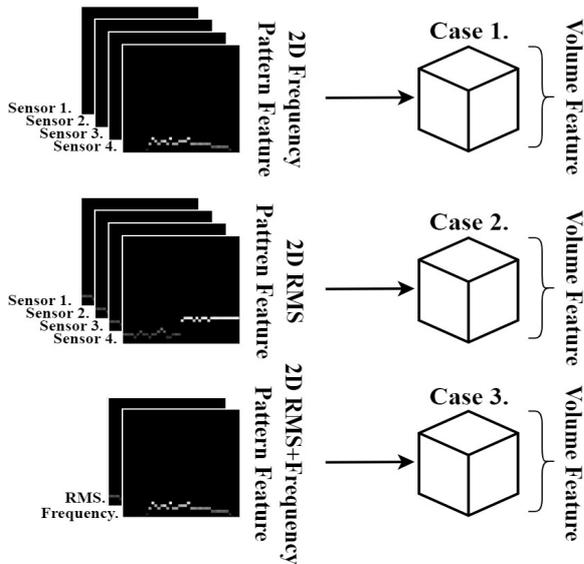


그림 3. 다중모드 볼륨 특징

Fig. 3. Multi-mode volume features

III. 누출판별을 위한 가중치 재분배 앙상블 모델

3.1 ResNet 단일 학습 모델

본 연구에서는 미세한 배관 누출 신호와 정상 신호를 분류하는 데 있어, 더 깊고 복잡한 표현을 학

습하기 위해 CNN(Convolution Neural Network)[7] 분야에서 성능이 우수한 ResNet(Residual Network)[8] 기반의 단일모델을 설계하였다. ResNet은 깊은 네트워크의 학습 문제를 해결하고자 개발된 모델로, 그라디언트 소실 문제 등을 극복하기 위해 잔차 블록(Residual block)이라는 개념을 도입한 것이 특징이다. 잔차 블록은 각 층의 입력을 해당 층의 출력에 직접 더하는 방식으로 작동한다. 본 연구에서는 그림 4와 같은 ResNet 단일모델을 활용하여 플랜트 배관계의 누출 신호와 정상 신호를 분류하였다.

ResNet 단일모델은 컨볼루션 연산 시 3×3 크기의 필터 마스크를 적용하였으며, 각 잔차 블록에 16개와 32개의 특징맵 필터를 사용한 2개의 잔차 블록을 활용하였다. 또한, 각 잔차 블록 안에서는 컨볼루션 연산 후 BatchNormalization[9]을 수행함으로써 내부 공변량 이동(Internal covariate shift) 문제를 해결하고, 모델의 학습을 더욱 안정시켰다. 컨볼루션 층의 활성화 함수로는 ReLU(Rectified Linear Unit)를 적용하였고, 이 외에도 특징맵에 존재하는 모든 특징에 대한 평균을 계산하고, 1차원 벡터를 생성하는 GAP(Global Average Pooling)을 적용하여 대표적인 특징들을 추출하였다. 마지막으로, 누출 신호와 정상 신호를 분류하기 위해 완전 연결 층(Fully connected layer)을 추가하였다. 이때, 활성화 함수로는 Sigmoid 함수를 적용하였다.

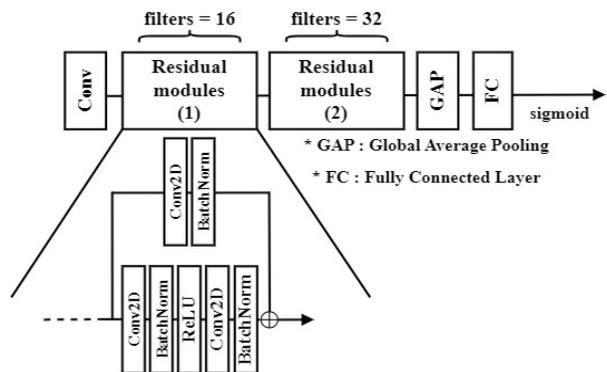


그림 4. ResNet 모델 아키텍처

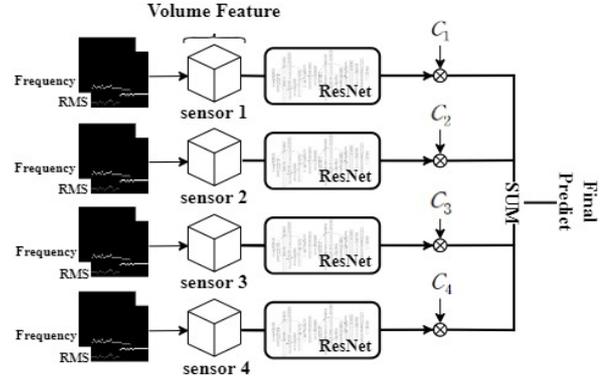
Fig. 4. ResNet model architecture

3.2 가중치 재분배 앙상블 기법을 활용한 구조

본 연구에서는 단일모델의 성능 한계를 극복하고 더욱 향상된 누출판별을 위한 분류 정확도 성능을

도출하는 방법으로 앙상블 기법을 적용하였다. 이 방법은 여러 개의 독립적으로 학습된 모델들의 예측을 결합하는 전략으로, 서로 다른 특성을 감지하는 다양한 모델들의 활용을 통해, 개별 모델이 감지하지 못하는 세부적인 패턴이나 특성을 보완하며, 전반적인 성능을 강화한다[10][11]. 이와 관련해서, 앙상블 기법은 이미지 분류 작업에서의 연구가 지속해서 진행되어왔다[12]-[15]. 그림 5는 본 연구에서 제안하고 있는 다중모드 특징융합 가중치 재분배 앙상블 구조를 상세하게 나타내고 있다. 이를 통해, 플랜트 배관계의 미세 누출 신호와 정상 신호에 대한 분류 정확도를 향상시키고자 한다.

먼저, 그림 5(a)는 그림 3의 Case 1과 Case 2에 해당하는 볼륨 특징을 이용하여 도메인별로 앙상블 한 구조를 보여준다. 반면에, 그림 5(b)의 경우에는 그림 3의 Case 3에 해당하는 볼륨 특징으로 구성하여 센서별로 앙상블 한 구조를 보여준다. 이 과정에서, 학습된 모델 간의 성능 불균형은 앙상블 성능을 저해시킬 수 있는 주요한 문제를 일으킬 가능성이 있다. 이러한 문제를 해결하기 위한 다양한 연구들이 현재 진행되고 있으며, 그중에서 가장 주목받는 방법이 가중치 재분배를 통한 앙상블 기법이다[16][17].



(b) 주파수 및 RMS 볼륨 특징을 이용한 센서별 앙상블 모델
 (b) Sensor-specific Ensemble Model using Frequency and RMS Volume Features

그림 5. 볼륨 특징을 이용한 앙상블 모델
 Fig. 5. Ensemble model using volume feature

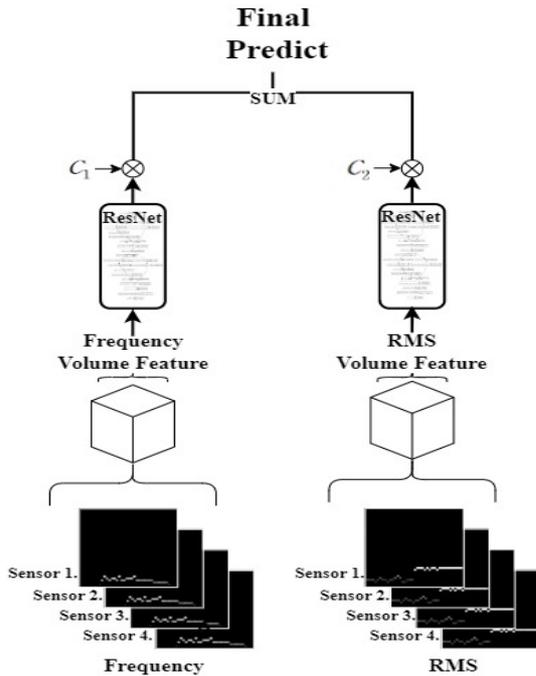
본 논문에서는 모델 간의 성능 불균형 문제를 극복하기 위해 모델 간 예측 성능의 가중치를 소프트맥스 기반 재분배 방법을 제안하여, 이를 통해 앙상블 모델의 성능을 개선하고자 한다. 각각의 앙상블 구조에 적용된 가중치는, 각 모델의 학습 과정이 종료된 이후, 식 (1)을 바탕으로 정확도 성능에 소프트맥스 기반 가중치 재분배를 적용하였다.

$$c_i = \frac{e^{c_i}}{\sum_{i=1}^N e^{c_i}}, i = 1, 2, \dots, N \quad (1)$$

식 (1)에서 N은 앙상블에 적용된 모델의 개수를 나타낸다. 이 방법은 각 모델의 예측 성능에 따라 가중치를 소프트맥스 기반으로 재분배하여, 각 모델이 가진 특성을 보다 효과적으로 반영하게 한다. 특히, 높은 성능을 제공하는 모델에 더 많은 가중치를 부여함으로써 전체 앙상블 모델의 성능을 향상시킬 수 있다. 이런 접근 방식은 앙상블 학습의 효과를 극대화하며, 각 모델이 갖는 고유한 성능을 상호 보완적으로 활용할 수 있는 장점을 제공한다.

IV. 실험 결과

본 연구에서는 실험을 진행하기 위해 활용한 데이터들은 전체 데이터 세트를 훈련 세트와 테스트 세트로 8:2의 비율로 분할하여 구성하였다.



(a) 주파수 및 RMS 볼륨 특징을 이용한 도메인별 앙상블 모델
 (a) Domain-specific ensemble model using frequency and RMS volume features

이후, 훈련 세트를 다시 부분 훈련 세트와 검증 세트로 8:2의 비율로 나누어 활용하였다. 또한, 모델 학습을 위한 특정 하이퍼파라미터로 Epoch는 30으로 설정하였고, 확률적 경사 하강법 기반의 학습 알고리즘을 선택하였다. 이때, 학습률 조정 방식으로는, 학습률을 동적으로 조정하는 방법을 적용하였다[18]. 또한, 학습을 위한 배치 사이즈는 64로 설정하였다. 상기에서 설정한 하이퍼파라미터를 활용하여 각 모델을 총 5회씩 학습시킨 후, 테스트 정확도 상위 3회의 값을 평균하여 도출한 결과는 표 1과 같이 주어진다.

표 1에서 모델 #1과 모델 #2는 각각 그림 3의 Case 1과 Case 2에 해당하는 볼륨 특징을 기반으로 한 ResNet 단일모델의 성능을 나타낸다. 실험 결과, 주파수 도메인의 특징을 이용한 모델 #2가 RMS 도메인의 특징을 이용한 모델 #1보다 상대적으로 더 높은 성능을 제공하는 것을 관찰할 수 있다. 한편, 모델 #3과 모델 #4는 각각 2D 주파수와 RMS 패턴 특징을 센서별로 앙상블 한 구조의 성능을 보여준다. 모델 #4의 경우 모델 #2에 비해 성능 향상이 소폭 확인되었으나, 오히려 모델 #3은 모델 #1에 비해 성능 저하가 발생한 것을 확인할 수 있었다. 마지막으로, 상기에서 살펴본 모델들과 비교 시, 본 연구의 앙상블 조합을 적용한 모델 #5와 #6은 상대적으로 높은 성능을 제공함으로써 상위 모델로 분류되었다.

표 1. 모델별 테스트 정확도의 평균
Table 1. Average test accuracy of models

No	Model	Accuracy(%)	Rank
1	ResNet model using RMS volume feature	91.75	5
2	ResNet model using frequency volume feature	97.25	4
3	Sensor-specific ensemble model using 2D RMS pattern features	89.31	6
4	Sensor-specific ensemble model using 2D frequency pattern features	97.43	3
5	Domain-specific ensemble model using frequency and RMS volume features	98.17	2
6	Sensor-specific ensemble model using frequency and RMS volume features	98.91	1

한편, 그림 5의 앙상블 모델에서 ResNet을 이와 동일한 층수를 가지도록 설계한 잔차 연결이 없는 CNN 모델로 대체할 경우, 모델 #5에 대한 정확도 성능은 97.61%로 ResNet을 이용한 앙상블 모델보다 낮은 성능을 보여주었으나, 모델 #6의 경우에는 정확도 성능이 98.84%로 ResNet을 이용한 앙상블 모델과 거의 유사한 성능을 보여주었다. 결과적으로, 모델 #6의 분류 정확도 성능이 98.91%로 가장 높은 성능을 보여주는 것을 실험적으로 관찰할 수 있었다.

다음으로, 가장 높은 정확도 성능을 보여준 모델 #6의 성능 분석을 위해 혼동 행렬(Confusion matrix)을 작성하고 이를 그림 6에 제시하였다.

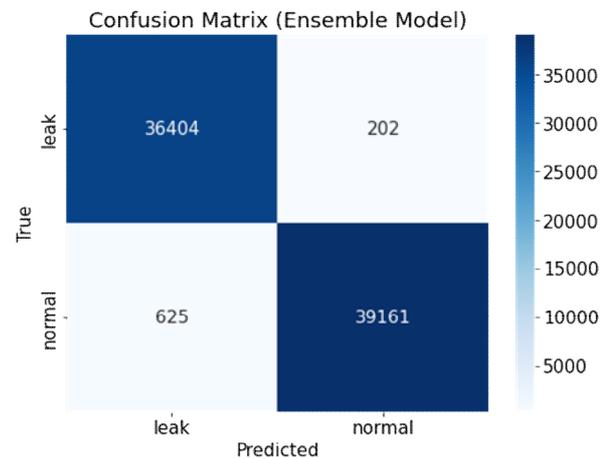


그림 6. 모델 #6의 혼동 행렬
Fig. 6. Confusion matrix of model #6

그림 6의 혼동 행렬을 기반으로 다음의 표 2는 모델 #5와 모델 #6에 대한 혼동 행렬을 비교한 결과를 보여준다. 표 3에서는 표 2의 결과를 바탕으로 혼동 행렬에 따른 평가 지표를 비교한 결과를 나타낸다. 여기서, 정밀도(Precision)는 $TP / (TP + FP)$ 로 계산되며, 모델이 Positive라고 예측한 사례 중 실제 Positive인 사례의 비율을 나타낸다. 다음으로, 재현율(Recall)은 $TP / (TP + FN)$ 으로 계산되며, 실제 Positive인 사례 중에서 모델이 Positive라고 정확히 예측한 사례의 비율을 나타낸다. 또한, F1 점수(F1 Score)는 정밀도와 재현율의 조화평균을 나타내며, $2 \times (Precision \times Recall) / (Precision + Recall)$ 로 계산한다. 먼저, 표 2를 관찰해보면, 모델 #6에 해당하는 TP와 TN의 값이 모델 #5보다 높고, FP와 FN의 값은 모델 #5보다 낮은 것을 확인할 수 있다.

또한, 표 3을 살펴보면, 모델 #6의 정밀도는 0.9831로 확인되었으며, 재현율은 0.9945, F1 점수는 0.9888로 모델 #6이 모델 #5보다 누출 신호 감지에 있어서 더 정확한 성능을 보여주는 것을 실험적으로 관찰할 수 있었다.

표 2. 모델 #5와 #6의 혼동 행렬

Table 2. Comparison of confusion matrix for models #5 and #6

Model	TP	TN	FP	FN
#5	36,205	38,753	1,033	356
#6	36,404	39,161	625	202

* TP : True Positive, TN : True Negative, FP : False Positive, FN : False Negative

표 3. 모델 #5와 #6의 혼동 행렬의 평가 지표

Table 3. Comparison of confusion matrix assessment indicators for model #5 and model #6

Model	Precision	Recall	F1 score
#5	0.9722	0.9902	0.9811
#6	0.9831	0.9945	0.9888

V. 결론 및 향후 과제

본 논문에서는 플랜트 배관계에서 발생하는 미세 누출을 판별하기 위해, 음향 센서 데이터에서 2D 패턴 특징을 추출하고 이를 바탕으로 다양한 볼륨 특징을 구성하는 등의 다중모드 특징융합과, 이를 적용한 가중치 재분배 앙상블 방법을 제안하였다. 실험 결과, 주파수와 RMS 볼륨 특징을 활용한 센서별 앙상블 모델이 98.91%의 가장 좋은 성능을 제공하는 것을 실험적으로 관찰하였다.

향후 연구에서는 다양한 조건의 누출 데이터 학습 및 다른 응용 도메인으로의 전이 학습 적용을 고려하기 위하여, 다양한 모델에 대한 다중모드 앙상블 구조 연구와 함께, 앙상블 기법에서의 가중치 재분배를 더욱 효율적으로 수행하기 위한 자동화된 방법에 관한 연구를 수행할 예정이다.

Acknowledgments

본 논문은 2023년도 한국정보기술학회 하계종합 학술대회에서 발표한 내용을 확장한 연구 결과임.

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

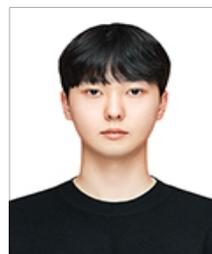
References

- [1] 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, Nov. 2009. <https://doi.org/10.1016/j.jlpp.2008.08.009>.
- [2] 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, Oct. 2016.
- [3] 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, Sep. 2019. <https://doi.org/10.9708/jksci.2019.24.09.021>.
- [4] 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" *Proc. of KIIT Conference*, JeJu, Korea, pp. 431-435, Jun. 2021.
- [5] 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.
- [6] J.-H. Bae, D. Yeo, D.-B. Yoon, S. W. Oh, G. J. Kim, N.-S. Kim, and C.-S. Pyo, "Deep-Learning-Based Pipe Leak Detection Using Image-Based Leak Features", *Proc. of the IEEE International Conference on Image Processing (ICIP)*, Athens, Greece, pp. 2361-2365, Oct. 2018. <http://doi.org/10.1109/ICIP.2018.8451489>.

- [7] 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, Nov. 1998. <https://doi.org/10.1109/5.726791>.
- [8] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition", In Proc. of the IEEE conference on computer vision and pattern recognition, Las Vegas, USA, pp. 770-778, 2016. <https://doi.org/10.48550/arXiv.1512.03385>.
- [9] S. Ioffe and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift", In Proc. of the 32nd International Conference on Machine Learning, Lille, France, pp. 448-456, Jul. 2015. <https://doi.org/10.48550/arXiv.1502.03167>.
- [10] S.-W. Park, J.-C. Kim, and D.-Y. Kim, "A Study on Classification Performance Analysis of Convolutional Neural Network using Ensemble Learning Algorithm", Journal of The Korea Society of Multimedia Society, Vol. 22, No. 6, pp. 665-675, Jun. 2019. <https://doi.org/10.9717/kmms.2019.22.6.665>.
- [11] J. W. Yang, Y. D. Lee, and I. S. Koo, "Sensor Fault Detection Scheme based on Deep Learning and Support Vector Machine", The Journal of The Institute of Internet, Broadcasting and Communication (IIBC), Vol. 18, No. 2, Apr. 2018. <https://doi.org/10.7236/IIBC.2018.18.2.185>.
- [12] Y. B. Cho, "Classification Algorithm for Liver Lesions of Ultrasound Images using Ensemble Deep Learning", The Journal of The Institute of Internet, Broadcasting and Communication (IIBC), Vol. 20, No. 4, Aug. 2020. <https://doi.org/10.7236/IIBC.2020.20.4.101>.
- [13] Y. Chen, Y. Wang, Y. Gu, X. He, P. Ghamisi, and X. Jia, "Deep Learning Ensemble for Hyperspectral Image Classification", IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 12, No. 6, Jun. 2019. <https://doi.org/10.1109/JSTARS.2019.2915259>.
- [14] J. Y. Hwang, B. A. Choi, J. H. Lee, and J. H. Bae, "A Study on Transfer Learning-based Ensemble Model for Classification of Maneuver Weapon System", Journal of the Korea Information Technology Society, Vol. 19, No. 12, Dec. 2021. <https://doi.org/10.14801/jkiit.2021.19.12.1>.
- [15] J. Y. Hwang and J. H. Bae, "Performance Comparison of Transfer Learning Based Feature Fusion Method and Ensemble Model", Proc. of KIIT Conference, JeJu, Korea, pp. 205-205, Jun. 2022.
- [16] H. Jung, M.-K. Choi, J. Kim, S. Kwon, and W. Jung, "CNN-based Weighted Ensemble Technique for ImageNet Classification", Journal of the Korean Institute of Embedded Engineers, Vol. 15, No. 4, pp. 197-204, Aug. 2020. <https://doi.org/10.14372/IEMEK.2020.15.4.197>.
- [17] J. Y. Hwang and J. H. Bae, "A Study on Probability Distribution-Based Weight Redistribution Ensemble Technique to Improve Classification Accuracy", Proc. of KIIT Conference, JeJu, Korea, pp. 285-285, Dec. 2022.
- [18] Keras Documentation, "Reduce learning rate when a metric has stopped improving", https://keras.io/api/callbacks/reduce_lr_on_plateau [accessed: Jul. 5, 2023].

저자소개

권 성 수 (Sungsoo Kwon)



2023년 2월 : 대구가톨릭대학교
컴퓨터정보학부
인공지능·빅데이터공학전공
(공학사)

2023년 3월 ~ 현재 :
대구가톨릭대학교

AI빅데이터공학과 석사과정

관심분야 : 인공지능, 딥러닝/머신러닝

전 서 영 (Seoyoung Jeon)



2021년 3월 ~ 현재 :
대구가톨릭대학교
AI빅데이터공학과 학사과정
관심분야 : 인공지능,
딥러닝/머신러닝

배 지 훈 (Ji-Hoon Bae)



2000년 2월 : 경북대학교
전자·전기공학부(공학사)
2002년 2월 : 포항공과대학교
전자컴퓨터공학부(공학석사)
2016년 2월 : 포항공과대학교
전자·전기공학과(공학박사)
2002년 1월 ~ 2019년 8월 :

한국전자통신연구원 책임연구원

2019년 9월 ~ 현재 : 대구가톨릭대학교 AI빅데이터공학과
조교수

2021년 3월 ~ 현재 : 대구가톨릭대학교 SW중심대학사업단
SW기초교육센터장

관심분야 : 인공지능, 딥러닝/머신러닝, 레이다 영상 및
신호처리, 최적화 기법

최 유 락 (Yurak Choi)



1991년 2월 : 충남대학교
컴퓨터공학과(공학사)
1993년 2월 : 충남대학교
컴퓨터공학과(공학석사)
2022년 2월 : 충남대학교
컴퓨터공학과(공학박사)
1993년 3월 ~ 현재 :

한국원자력연구원 책임연구원

관심분야 : 원자력, 클라우드, 인공지능, 스마트 감지 및
진단

이 종 혁 (Jonghyuk Lee)



2004년 2월 : 고려대학교
컴퓨터교육과(이학사)
2006년 2월 : 고려대학교
컴퓨터교육과(이학석사)
2011년 2월 : 고려대학교
컴퓨터교육과(이학박사)
2011년 3월 ~ 2011년 10월 :

고려대학교 정보창의교육연구소 연구교수

2011년 11월 ~ 2012년 11월 : University of Houston
Post-Doc. 연구원

2012년 12월 ~ 2017년 8월 : 삼성전자 책임연구원

2017년 9월 ~ 현재 : 대구가톨릭대학교

AI빅데이터공학과 조교수

관심분야 : 클라우드 컴퓨팅, 빅데이터, 인공지능