

선박용 밸브의 내부 누설 진단을 위한 음향방출신호의 머신러닝 기법 적용 연구

이정형^{**}

* 목포해양대학교 기관시스템공학부 교수

Diagnosis of Valve Internal Leakage for Ship Piping System using Acoustic Emission Signal-based Machine Learning Approach

Jung-Hyung Lee^{**†}

* Professor, Division of Marine System Engineering, Mokpo Maritime University, Mokpo, Republic of Korea

요 약 : 밸브의 내부 누설 현상은 밸브의 내부 부품의 손상에 의해 발생하며 배관 시스템의 사고와 운전정지를 일으키는 주요 요인이다. 본 연구는 버터플라이형 밸브의 내부 누설에 따라 배관계에서 발생하는 음향방출 신호를 이용하여 배관 가동 중 실시간 누설 진단의 가능성을 검토하였다. 이를 위해 밸브의 작동 모드별로 측정된 시간영역의 AE 원시신호를 취득하였으며 이로부터 구축한 데이터셋은 데이터 기반의 인공지능 알고리즘에 적용하여 밸브의 내부 누설 유무를 진단하는 모델을 생성하였다. 누설 유무진단을 분류의 문제로 정의하여 SVM 기반의 머신러닝과 CNN 기반의 딥러닝 분류 알고리즘을 적용하였다. 데이터의 특징 추출에 기반한 SVM 분류 모델의 경우, 이진분류 모델에서 구축된 모델에 따라 83~90%의 정확도를 나타냈으며, 다중 클래스인 경우 분류 정확도가 66%로 감소하였다. 반면, CNN 기반의 다중 클래스 분류 모델의 경우 99.85%의 분류 정확도를 얻을 수 있었다. 결론적으로 밸브 내부 누설 진단을 위한 SVM 분류모델은 다중 클래스의 정확도 향상을 위해 적절한 특징 추출이 필요하며, CNN 기반의 분류모델은 프로세서의 성능 저하만 없다면 누설진단과 밸브 개도 분류에 효율적인 접근방법임을 확인하였다.

핵심용어 : 밸브, 분류, 서포트 벡터 머신, 합성곱 신경망, 머신러닝, 딥러닝

Abstract : Valve internal leakage is caused by damage to the internal parts of the valve, resulting in accidents and shutdowns of the piping system. This study investigated the possibility of a real-time leak detection method using the acoustic emission (AE) signal generated from the piping system during the internal leakage of a butterfly valve. Datasets of raw time-domain AE signals were collected and postprocessed for each operation mode of the valve in a systematic manner to develop a data-driven model for the detection and classification of internal leakage, by applying machine learning algorithms. The aim of this study was to determine whether it is possible to treat leak detection as a classification problem by applying two classification algorithms: support vector machine (SVM) and convolutional neural network (CNN). The results showed different performances for the algorithms and datasets used. The SVM-based binary classification models, based on feature extraction of data, achieved an overall accuracy of 83% to 90%, while in the case of a multiple classification model, the accuracy was reduced to 66%. By contrast, the CNN-based classification model achieved an accuracy of 99.85%, which is superior to those of any other models based on the SVM algorithm. The results revealed that the SVM classification model requires effective feature extraction of the AE signals to improve the accuracy of multi-class classification. Moreover, the CNN-based classification can be a promising approach to detect both leakage and valve opening as long as the performance of the processor does not degrade.

Key Words : Valve, Classification, Support Vector Machine (SVM), Convolutional neural network (CNN), Machine learning, Deep learning

† jhlee@mmu.ac.kr, 061-240-7205

1. 서론

선박의 배관 시스템은 유체기계에 유체를 수송하는데 필요한 배관, 배관피팅, 밸브와 기타 기계장치로 구성된다. 밸브(valve)는 배관계에서 유체의 흐름을 차단, 제어하기 위해 통로를 개폐할 수 있는 가동기구를 가지는 기기를 말하며, 유체장치에서 중요 인자인 유량, 압력, 온도 등을 차단·제어하며 유체의 역류를 방지할 뿐만 아니라 배관의 안전을 담보하는 중요한 배관 요소이다. 밸브는 조작부, 밀봉부, 제어부, 압력용기부로 구성되며, 유체의 유량 제어와 직접 관련된 부분은 제어부 즉, 디스크(disc)와 시트(seat)이다.

밸브의 디스크와 시트는 유체의 흐름에 따라 마모되는 것이 자연적인 현상이나 유체 내의 이물질, 부식, 캐비테이션(cavitation), 수격현상(water hammering) 그리고 운전자의 오사용에 의해 손상이 가속화된다. 이 같은 손상은 시트와 디스크 간 습동면의 기밀 불량을 야기하여 밸브의 내부 누설을 일으키는 원인이 된다. 국내 산업용 밸브의 고장 데이터에서 고장 원인은 대부분 누설과 작동불량이며 누설일 경우 취약 부품은 시트, 패킹, 스템, 몸체 부분에 집중되어 있음을 알 수 있다(Kim and Kim, 2019).

밸브는 신뢰성 있는 작동을 보장하기 위해 주기적인 점검과 유지보수가 필요하다. 통상적으로 선박의 밸브는 정기입거 시 점검하여 수리 또는 교체를 실시한다. 만일 선박 운항 중 밸브 고장 시에는 유량 조절이 어려워 유체기계장치의 정상적인 운전이 불가능한 상황이 야기될 수 있다. 또한 밸브의 내부 누설은 유체의 완전한 차단을 어렵게 하므로 기계장치의 정비성이 낮아지므로 시스템의 리던던시(redundancy)를 저해하는 요소이다. 따라서 밸브의 내부 누설은 조기 진단하여 사고 발생을 미연에 방지하고 사전에 정비계획을 적절하게 수립하는 것이 중요하다.

가동 중 밸브의 내부 누설 진단 방법은 밸브 전후단의 유체의 압력, 유량, 온도 등의 물리량 차이로 판정하는 것이 일반적이며, 미소 누설 시에는 누설 상태에 대한 실시간 측정이 불가능하며 신뢰도가 떨어지는 문제점이 있다. 현재 선박에는 밸브 누설 진단을 위한 장치는 적용하고 있지 않으며, 청음봉을 이용해 누설에 따른 소음 유무로 누설을 판단하는 원시적인 방법을 사용하고 있다. 따라서 선박 배관계 밸브 내부 누설 진단의 신뢰도 향상을 위한 센서 기반의 진단 기술 개발이 필요한 실정이다.

센서를 이용한 밸브의 내부 누설 진단법은 주로 누설에 의해 발생하는 유체의 압력, 온도, 유량의 변화를 각각 압력 센서, 온도차센서, 초음파 유량 센서를 이용하여 탐지하는 방법이 연구되어 왔다. 이 같은 방법은 누설 시 유체기계의 종류, 운전조건(온도, 압력) 등에 대해 측정방법이 정량화

되어 있지 않아 현장 적용이 어려운 점이 있었다(Lee et al., 2007).

본 연구에서는 밸브의 내부 누설에 따라 배관계에서 발생하는 음향방출(Acoustic Emission, AE) 신호를 이용하여 배관 가동 중 실시간 누설 진단 가능성을 검토하고자 하였다. 이를 위해 밸브의 작동 모드별로 측정된 시간영역의 AE 원시 신호를 취득하였으며, 데이터 기반의 인공지능 알고리즘에 적용하여 밸브의 내부 누설 유무를 진단하는 실험을 진행하였다. 본 논문에서 제안한 진단 방법은 실제 배관 시스템을 축소된 랩 스케일의 시험 장치에서 밸브의 누설 모의를 통해 데이터를 얻었으며, 이에 대해 인공지능 알고리즘을 적용한 것에 의의가 있다. 본 논문의 구성은 2장에서 음향방출의 측정 방법과 밸브 작동 모드별 AE 원시 신호 취득 방법에 대해 설명하고, 3장에서는 AE 신호 분석결과와 인공지능 알고리즘을 적용한 진단 결과를 제시하며, 마지막으로 4장에서는 결론과 시사점을 제시한다.

2. 실험방법

2.1 음향방출 현상




Fig. 1. Acoustic emission monitoring system.

음향방출은 재료의 균열과 같은 결함에 의해 고체 내부에 국부적으로 형성된 변형에너지가 급속하게 방출될 때 탄성파가 음향 에너지의 형태로 방출되는 현상이다. Fig. 1과 같이 음향방출원으로부터 발생한 신호는 매질을 통과하여 고체 표면에 설치된 탐촉자에 의해 검출되고 검출 신호는 신호처리기에 의해 저장, 수집, 분석을 함으로써 결함의 진단이 가능하다. 일정 시간동안 지속되는 AE 방출 사상(event)이 재료 내에서 발생하면 관측된 AE 신호파형은 그 사상의 특성에 대응하게 된다. Fig. 2는 전형적인 AE 신호파형과 파라미터를 나타낸 것이며, 주요 파라미터의 정의는 아래와 같다.

- 진폭(Amplitude): 포락선의 최대 진폭값으로 정의한다.
- 발생빈도(Count): AE 신호의 발생 회수이며 문턱값(Threshold)을 초과하는 파고의 수이며 음향방출원의 발생빈도를 나타낸다.

- 에너지(Energy): 포락선 하부의 면적이며 음향방출 신호의 에너지를 나타낸다.
- 상승시간(Risetime): 문턱값을 초과하는 최초의 시각부터 최대진폭까지의 시간
- 유지시간(Duration): 사상이 진행되는 신호의 길이




Fig. 2. Waveform of acoustic emission and AE parameters.

AE신호는 시간에 따른 파동의 형태로 수집된다. 수집된 AE 신호의 분석 기법에는 시간영역분석, 주파수 영역 분석, 시간-주파수 영역 분석의 3가지 접근 방법이 있다(Li, 2002). 시간영역(Time domain) 분석은 신호의 시간에 따른 변화를 관측하는 것으로 시간영역의 원시 데이터의 파라미터 특성 값과 이들의 평균치, 실효치 등과 같은 통계량 파악하는 것이다. 주파수 영역(Frequency domain) 분석은 주어진 시간영역의 데이터를 주파수 스펙트럼으로 변환하여 주파수 영역 내의 숨겨진 정보를 파악하여 음향 방출원의 기구를 규명하는데 초점이 맞추어져 있다. 주파수 영역 변환은 고속푸리에변환(Fast fourier transform)이 일반적이며, 짧은 시간에 발생하는 급격한 변화를 감지하기 힘들다는 단점이 있다. 이를 보완한 것이 시간-주파수 영역(Time-frequency domain) 분석이며 주파수 성분의 시간에 대한 변화를 관측한다. 시간-주파수 신호 변환은 short-time 푸리에 변환과 연속 웨이블릿 변환이 일반적으로 사용된다(Ahadi and Bakhtiar, 2010).

2.2 폐쇄 회로 배관에서의 AE신호 측정

Fig. 3은 유체 흐름에 노출된 밸브로부터 방출되는 AE 신호를 측정하기 위해 본 연구에 사용된 실험실 규모의 배관 시스템이다. 유체를 지속적으로 순환시킬 수 있도록 펌프, 탱크, 냉각기를 폐쇄회로로 구성하였다. AE센서는 진단 대상 밸브 후단부의 배관 표면에 설치하여 밸브 내부로부터 방출되는 음향신호를 측정하도록 하였다. 본 연구는 유체 시스템의 가동 중 밸브의 누설을 진단하는 것이 목적이며,

밸브 진단을 위해서 밸브의 개도를 조절하여 음향 방출 신호를 취득하였다. 밸브의 내부 누설은 밸브가 닫힌 상태에서 유체가 흐르는 현상으로 정의하였다. 정상 모드는 밸브의 개도에 따른 5개의 상태, 고장 모드는 시트 손상과 디스크 손상으로 구분하여 폐쇄상태에서 측정된 2개의 상태, 총 7개의 작동 모드에 따라 신호를 취득하였다. Table 1은 밸브의 작동 모드에 따라 본 논문에서 표기된 부호와 상태를 정리하였다. AE 신호 측정 시 유체 변화에 의한 영향을 최소화하기 위해 펌프의 회전속도는 1800 rpm으로 유지시켜 동일한 유속이 발생하도록 하였고, 온도는 20°C로 유지시켰다.




Fig. 3. Acquisition of AE signal from valve using lab-scale piping system.

Table 1. Designation of valve operation modes

Code	Description
DD	Valve with damaged disc
DS	Valve with damaged seat
New_0	New valve with 0% opening (=Full closed)
New_20	New valve with 20% opening
New_50	New valve with 50% opening
New_80	New valve with 80% opening
New_100	New valve with 100% opening (=Full open)

Fig. 4는 진단 대상 밸브의 사진을 나타내었다. 밸브의 종류는 버터플라이형 밸브이며, 밸브의 구조는 밸브 조작부(1), 몸체(2), 시트(3), 디스크(4), 스프링(5)의 주요 구성품으로 이루어진다. (a)는 밸브의 전폐 상태(밸브 개도: 0%)이고, (b)는 전개 상태(밸브 개도: 100%)를 나타낸다. 밸브 디스크와 시트 손상에 따른 내부 누설은 밸브의 구성품 중 시트와 디스크에 인위적인 고장을 부여하였다. 디스크의 손상의 경우 이물질이 디스크와 시트 사이에 고착된 상태에서 무리하게

밸브 조작을 하여 디스크에 손상이 발생한 것을 모사하였고, 시트 손상은 밸브의 빈번한 조작 시 발생 가능한 상황을 상정하여 고무재질의 시트부를 마모시켰다.




Fig. 4. Photo of butterfly valve.




Fig. 5. Schematic diagram of acoustic emission measurement setup.

Fig. 5는 AE 신호 취득에 사용된 장비의 구성도를 나타낸다. AE 신호 측정 시스템은 AE 센서, 신호 증폭기, 데이터 수집장치 및 PC 기반의 분석 시스템으로 구성된다. 진단 대상 밸브로부터 방출된 AE신호는 배관 내부 표면을 따라 AE 센서(Physical acoustics, 150 kHz 공진형)에 전달되며, 신호 증폭기를 통해 전기적 신호로 증폭되어 최종적으로 진단 및 해석이 수행되는 음향방출 분석 시스템(MISTRAS, AEWIN™)으로 전송된다. AE센서 신호는 주위 잡음의 크기 및 발생하는 음향방출 신호의 크기 등을 고려하여 문턱값(Threshold)을 10 dB로 고정하여 측정하였으며 증폭기에서 40 dB로 증폭시켰다. 증폭기의 주파수 대역은 100 kHz에서 600 kHz이며, 샘플링 속도는 10 MS/s이다.

3. 실험 결과 및 고찰

3.1 AE 신호 파형 분석

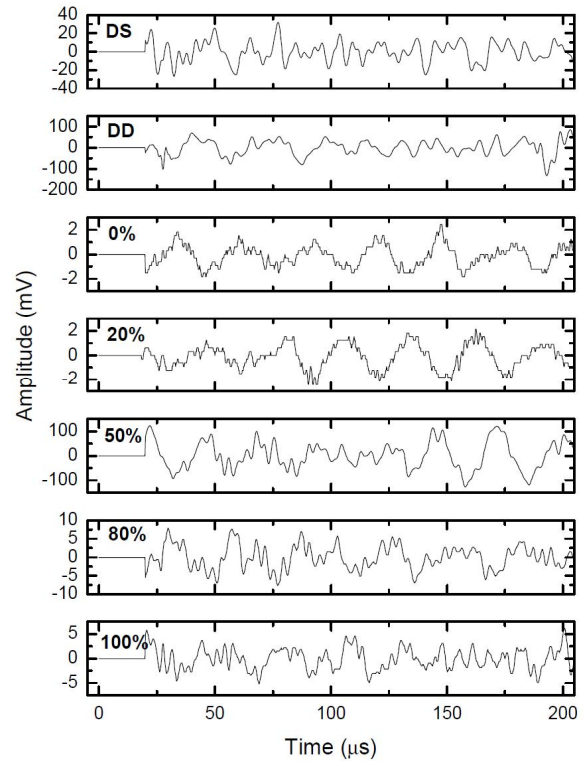


Fig. 6. Time domain raw AE signal for different valve operation modes.

Fig. 6은 7개의 밸브 작동 모드에 해당하는 최초의 Hit 데이터에 대한 200 μ s 동안(1024 데이터 포인트)의 원시데이터 파형을 나타낸 것이다. 일반적으로 AE 신호는 파형의 형상에 따라 연속형(continuous type)과 돌발형(burst type)으로 구분된다. 연속형은 주로 유체의 누설과 재료의 소성변형 시 발생하는 AE이며, 돌발형은 재료의 균열의 생성과 파괴에서 발생하는 음향방출의 형태이다(Ozevin and Harding, 2012). 본 연구는 밸브를 통과하는 유체의 흐름이 밸브의 개도 변화와 누설에 따라 발생하는 것을 음향방출원으로 하므로 7개의 밸브 작동 모드에서 모두 연속형 음향방출이 관찰되었다. 그러나 시간영역에서 측정된 AE의 원신호는 밸브의 작동모드 별 식별 가능한 특징은 관찰되지 않았다. 이는 AE 신호의 작동모드 별 데이터를 이용한 머신러닝과 딥러닝 알고리즘 기반의 분류와 밸브의 내부 누설 진단이 가능함을 시사한다.

Table 2는 7개 밸브의 작동 모드 별로 180초간 측정된 AE 원시 데이터에서 얻은 주요 파라미터의 통계량을 정리한 것이다. Fig. 6의 원시데이터에서와 마찬가지로 밸브 개도 별로 일정한 경향성은 확인되지 않았다.

Table 2. Key AE parameters for different valve operation modes

Valve mode	Total AE hits	Count	Energy	Amplitude (dB)	ASL (dB)	Average frequency	RMS
DD	207	2682.464	50590.37	73.6667	55.1449	2.1981	0.0398
DS	198	17298.89	25333.24	74.7929	49.4545	16.7879	0.0209
0%	186	7159.618	785.3978	33.1613	20.9194	6.6989	0.0008
25%	201	9182.309	690.1144	32.6318	19.6517	8.6567	0.0007
50%	183	9283.273	65400.23	86.6503	59.5082	8.8197	0.0673
75%	188	28748.38	4501.309	61.1277	34.4894	28.266	0.0038
100%	237	19910.85	5308.363	59.9494	35.7975	19.4219	0.0044

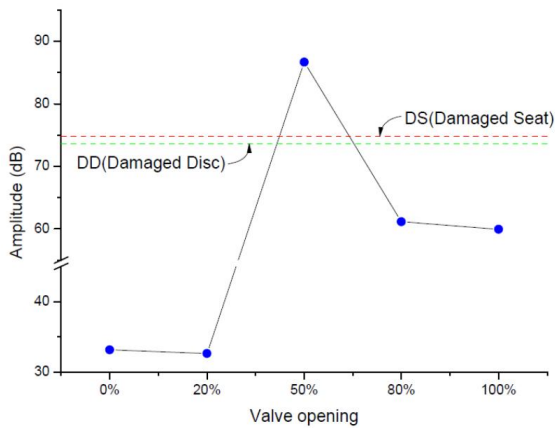


Fig. 7. Comparison of AE amplitude vs valve opening.

Fig. 7은 Table 2의 파라미터 중 진폭값을 개도별로 비교한 것이다. AE 파형에서 진폭은 분석의 기본 파라미터로서 재료의 물리적 특성과 연관이 있다. AE 신호의 진폭은 밸브 개도 50%에서 86.6503 dB가 측정되어 가장 큰 값이 관찰되었으며, 가장 작은 진폭은 밸브 개도 0%, 즉 밸브가 폐쇄된 상태에서 관찰되었다. 밸브 개도 50%의 경우 신호 측정 시 가장 큰 진동과 소음이 발생하였다. 이와 같은 진동과 소음은 밸브 폐쇄에 따른 유체의 압력 변화에 의한 것으로 수동 밸브와 자동 조절 밸브에서 모두 발생할 수 있는 현상이다. 밸브 누설 모드인 DD와 DS는 밸브 개도 50%를 제외한 다른 밸브 개도보다 높은 진폭을 나타내었다. 밸브 개도 별로 진폭 변화는 일정한 경향성은 없고, 0%와 20%가 유사한 수준을 나타내고 80%와 100% 개도가 0% 및 20% 개도에 비해 약 2배가량 큰 진폭을 나타내었다. 두 고장 모드인 DD와 DS 간의 진폭의 큰 차이를 확인되지 않았다.

본 연구는 가동 중인 배관 시스템에서 밸브 폐쇄 상태에서 취득한 AE 신호를 분석하여 누설 유무를 판단하고자 하

므로 상기와 같은 파형 데이터를 기반으로 하여 머신러닝 및 딥러닝을 활용한 분류 문제를 아래와 같이 3가지 경우로 정의하였다.

- 1) 밸브 폐쇄 상태를 정상 상태로 하고 이로부터 각각 DD와 DS를 구분하는 문제
- 2) 밸브 폐쇄 및 개방(개도 0~100%) 상태를 정상 상태로 정의하고 누설을 이상상태로 정의하여 구분하는 문제
- 3) 7개의 모든 밸브 작동 모드를 별개의 클래스로 간주하여 분류하는 문제

1과 2는 이진 분류 문제이며 3은 다중 클래스 분류 문제라 볼 수 있다.

3.2 기계학습 방법

머신러닝(Machine learning)은 통상적으로 예측에 관한 문제를 다루며 예측에는 실수값을 예측하는 회귀(regression)와 부류를 예측하는 분류(classification)로 구분된다. 머신러닝에 의한 분류는 기존의 규칙이나 수식이 아닌 데이터로부터 추출한 특징 간의 관계를 파악하고 새롭게 관측된 데이터의 분류를 예측하는 과정이라 할 수 있다. 기계요소의 이상진단에 있어 분류의 문제로 접근하는 것은 기계에 장착된 센서로부터 데이터를 수집한 다음, 수집된 빅데이터에서 특징(feature)을 추출하고 정상 또는 이상 부류의 라벨링하여 학습을 진행하는 것을 말한다(Lei et al., 2020).

Fig. 8은 밸브 내부 누설 진단을 위한 데이터 준비, 학습, 분류 단계의 머신러닝 프레임 워크를 표현하고 있다. 데이터 준비 단계에서는 시간 영역의 원시 AE 파형을 200 μ s의 윈도우 단위로 구분하여 전처리를 실시하고 구분된 데이터들로부터 특징값을 추출하였다. Table 3은 7개의 밸브 작동 모드 별로 추출된 특징값을 나타낸 것이다. 추출된 특징값으로는 AE파형의 최대, 최소, 평균, RMS, 첨도(kurtosis), 왜도(skewness)와 같은 기초적 통계량을 사용하였다. 개별 신호에

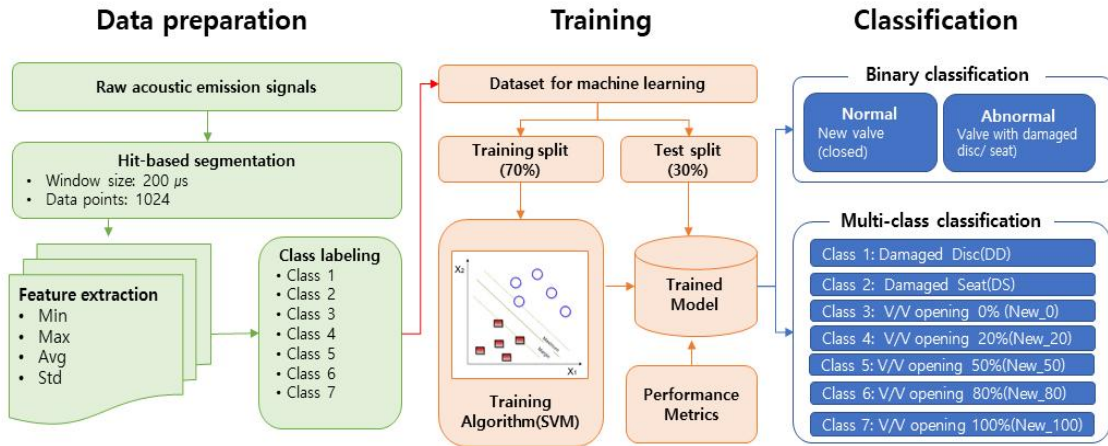


Fig. 8. Machine learning approach to classify the internal leakage of valve.

Table 3. Feature extraction from time domain raw AE waveform for different valve operation modes

Class	Max	Min	Average	Standard Deviation	RMS	Skewness	Kurtosis
DD	0.104065	-0.10315	-0.00054	0.035024	0.035012	-0.09269	0.541693
DS	0.039368	-0.04242	0.000108	0.015704	0.015697	-0.40045	-0.01817
0%	0.003967	-0.00366	-0.00018	0.001476	0.001486	0.250456	-0.43042
25%	0.00824	-0.01038	-0.00014	0.002904	0.002906	0.072281	1.053581
50%	0.169678	-0.21393	-0.00185	0.07164	0.071629	-0.46765	0.095849
75%	0.085449	-0.08392	-0.00033	0.028249	0.028237	0.20145	0.494152
100%	0.014648	-0.01495	-8.20E-05	0.005362	0.00536	0.006859	-0.25348

대해서는 7개의 밸브의 작동모드에 해당하는 라벨을 부여하였다. 이와 같이 준비된 데이터 셋은 훈련 세트와 테스트 세트로 구분하였다. 훈련세트는 전체 데이터 셋의 70%로 구성하여 머신러닝의 학습에 사용하였고, 나머지 30%의 데이터셋은 테스트 세트로서 알고리즘의 정확도 검증에 사용하였다. 적용한 분류 모델은 서포트 벡터 머신(Support Vector Machine)이며, 이는 선형이나 비선형 분류 문제, 회귀, 이상치 탐지 등에 사용 가능한 일반적인 다목적 알고리즘이다 (Durgesh and Lekha, 2010). 서포트 벡터머신은 데이터 부류를 구분하는 문제에 있어 경계를 계산하는 알고리즘이며, 경계는 각 부류 간 거리를 최대화할 수 있는 최적의 초평면을 구하게 된다.

7개의 밸브 작동 모드에 대한 AE 데이터로부터 추출된 특징값을 SVM을 이용하여 학습을 진행하였다. Table 4는 학습을 통해 구축한 4개의 이진 분류 모델과 1개의 다중 클래스 분류 모델에 대한 데이터 셋의 구성과 분류 성능 결과를 나타낸 것이다. 이진 분류 모델의 학습에 사용된 데이터 셋

의 구성은 4개로 구분하였다. SVM1은 폐쇄상태를 포함한 개도에 따른 4개의 밸브 개방 상태를 정상상태로 하였고, 디스크와 시트 손상 상태를 이상상태로 정의하였다. SVM2, SVM3, SVM4는 밸브 폐쇄상태를 정상 상태로 보고 이상 상태는 디스크 손상 또는 시트 손상을 이상으로 정의하여 데이터 셋 수와 그 구성 비율을 달리하였다. 마지막으로 SVM5는 7개의 다중 클래스 분류를 위해 각 클래스 별 500개의 데이터 셋을 사용한 것이다. 분류 성능 지표는 부류 간 데이터 셋의 수가 불균형한 SVM1의 경우 F1 score를 사용하였으며, 나머지 모델은 정확도(Accuracy)를 사용하였다.

이진분류 모델 중 가장 높은 분류 성능을 나타낸 모델은 SVM2로 정확도 90%를 나타내었으며, 나머지 이진분류 모델은 이보다 떨어진 83~84%의 분류 성능을 나타내었다. 이 같은 성능의 차이는 데이터 셋에 의한 서포트벡터 머신의 알고리즘 특성 때문인 것으로 판단된다. 서포트벡터머신은 부류의 수가 유사한 데이터 셋에서는 우수한 분류 성능을 나타내지만 부류의 수가 불균일할 경우 성능이 떨어진다고

Table 4. Classification models of valve internal leakage: datasets and result of performance metrics

Binary Classification									
Model	No. of datasets							Performance metric	
	Normal					Abnormal			
	0%	20%	50%	80%	100%	DD	DS		
SVM1	500	500	500	500	500	1000	1000	F1 score	0.849
SVM2	500					250	250	Accuracy	0.9
SVM3	500					500		Accuracy	0.853
SVM4	500						500	Accuracy	0.833

Multi-class Classification									
Model	No. of datasets							Performance metric	
	0%	20%	50%	80%	100%	DD	DS		
SVM5	500	500	500	500	500	500	500	Accuracy	0.660

알려져 있다(Farquad and Bose, 2012). 여기서 데이터 셋이 불균일하다는 것은 데이터 셋의 부류가 한쪽으로 크게 편향되어 분포하는 데이터를 말한다. 이 같은 점에서 서포트벡터머신에 의한 밸브 내부의 누설 진단 시 학습 데이터 셋의 구성은 성능 향상에 중요한 요소로 판단된다.

한편, 다중 클래스 분류 모델(SVM5)은 이진 분류 모델에 비해 낮은 정확도인 66%를 나타내었다. 이진분류 모델에 비해 성능이 저하된 이유는 Fig. 9의 SVM5에 대한 혼동 매트릭스로부터 확인할 수 있다. 이상 상태인 DD와 DS의 경우 각각 85%와 93%의 정확도를 나타내어 이진 분류 모델과 유사한 수준이었다. 이러한 분류 성능으로 볼 때 통계값으로 추출한 특징이 밸브 폐쇄 및 개방 상태와 구분되도록 비교적 잘 선정되었다고 간주할 수 있다. 그러나 SVM5는 밸브 개방 상태의 경우, 인접한 밸브 개도, 즉 0%와 20%, 80%와 100%의 개도를 혼동하는 경향을 보였다. 밸브 폐쇄된 상태인 개도 0%가 20%와 혼동을 일으킨 것은 실제 핸들 조작은 폐쇄를 하였지만 밸브를 분해하여 확인한 결과 극소량 개방되어 있는 상태였기 때문으로 확인되었다. 또한 DD의 경우 밸브 개도 50%와 상호 혼동을 일으키는 것으로 확인되었다. 밸브 개도 50%는 실험 시 소음과 진동 발생이 크게 발생한 조건으로 디스크 손상 시 특징값과 유사한 특징값이 생성되어 이러한 혼동이 발생한 것으로 판단된다. 정리하면 SVM 알고리즘 기반의 머신러닝에 의한 다중 분류 모델은 밸브의 개도에 대한 인접 부류와 개도 50%에서의 분류 성능은 떨어지며, 누설 자체 즉, 디스크와 시트 누설에 의한 이상 분류의 성능은 상대적으로 양호한 것으로 보인다.




Fig. 9. Confusion matrix for SVM-based multi-class classification.

3.3 딥러닝

본 연구에서 밸브 작동 모드 분류를 위해 적용한 알고리즘은 합성곱 신경망(Convolutional Neural Network, CNN)이다. CNN은 이미지 인식에 주로 사용되는 인공 신경망의 일종으로 합성곱 연산을 이용하여 이미지로부터 특징을 추출하여 분류를 수행한다. CNN에 의한 분류 알고리즘은 비단 이미지 뿐만 아니라 이미지 형태로 변환 가능한 신호에도 적용할 수 있다. 즉, 소음이나 진동 신호를 스펙트로그램으로 변환하여 이를 CNN 입력층에 적용하여 이상진단에 활용할 수 있다(Zhao et al., 2021).

선박용 밸브의 내부 누설 진단을 위한 음향방출신호의 머신러닝 기법 적용 연구




Fig. 10. Architecture of the CNN model for multi-class classification.

Fig. 10은 7개의 밸브 작동 모드에 대해 다중 클래스 분류를 위한 CNN의 계층 구조를 나타낸 것이다. CNN의 계층 구조는 특징을 추출하는 2개의 합성곱층, 풀링층 및 분류를 수행하는 완전 연결층으로 구성되어 있다. 입력층에는 1024개의 데이터 포인트를 가진 시간영역의 AE의 원신호가 32×32의 행렬의 형태로 입력되어 합성곱층으로 전달되며, 입력값은 커널(kernel)을 이용하여 합성곱 연산의 결과가 활성화 함수(ReLU)를 거치게 된다. 이후 풀링층에서는 특성 맵을 다운샘플링하는 풀링 연산을 수행한 다음 완전 연결층의 입력으로 전달된 후 최종적으로 분류가 수행된다.

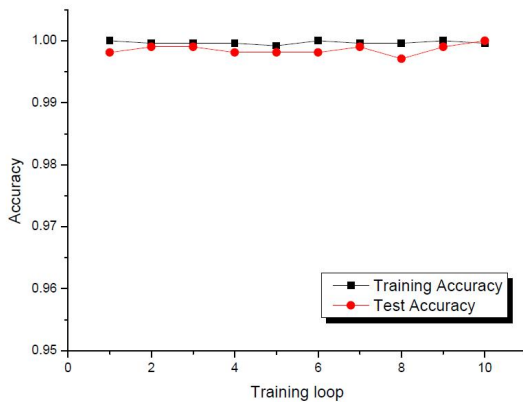


Fig. 11. Training and test accuracy evolution with loop.

Fig. 11은 학습 epoch를 45, 배치 크기를 128 그리고 학습률을 0.001로 설정하여 10회 반복에 따른 훈련 정확도와 검증 정확도의 추이를 나타낸 것이다. 학습 epoch에 따른 훈련 정확도와 검증 정확도는 큰 변화가 없이 100%에 가까운 값을 나타내며 둘 간의 큰 차이는 확인되지 않았으므로 과적합 발생 없이 원활하게 학습된 것으로 판단된다. 10회 반복에 대한 검증 정확도의 평균은 99.85%로 100%에 가까운 정확도를 보였다. 비교적 단순한 CNN 구조와 하이퍼 파라미터 최적화를 고려하지 않은 점을 감안하면 비교적 높은 정확도라고 볼 수 있다.

Fig. 12는 구축된 딥러닝 분류 모델에 대해 밸브모드의 각 클래스 별 분류 정확도를 확인할 수 있는 혼동 매트릭스를

제시하였다. 본 연구에서 적용한 CNN 모델은 정답이 DD부류에서 DS로 오분류하는 1건을 제외하고 모두 100%의 분류 정확도를 나타내었다. 머신러닝에 의한 다중 클래스 분류 모델인 SVM5의 정확도(66%)와 비교하면 특징 추출 과정 없이도 높은 정확도가 얻어졌다.

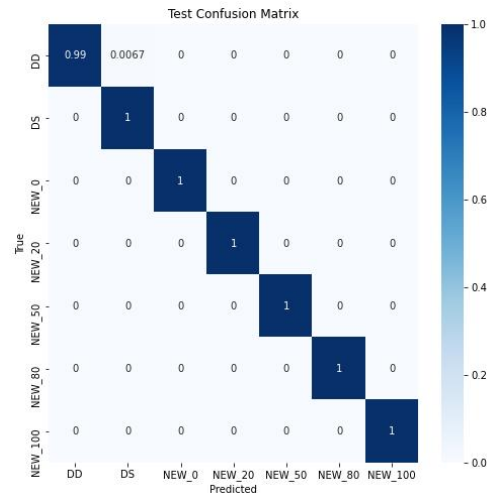


Fig. 12. Confusion matrix for CNN-based multi-class classification.

4. 결론

본 연구는 음향방출 신호를 이용하여 버터플라이형 밸브의 내부 누설 진단을 위해 머신러닝과 딥러닝 알고리즘의 적용을 시도하였다. 밸브 내부의 누설 진단은 배관 시스템의 가동 중 밸브의 구성요소인 디스크와 시트 손상에 의한 내부 누설 시 진단모델을 구축하고자 하였다. 이를 위해 밸브의 개방과 누설 상태에 따른 7개의 작동 모드로 구분하고 각각에 대한 AE 데이터를 취득하였다. 취득한 데이터는 시계열 원시 데이터로서 각 모드 별 패턴이나 특징은 구분하기 어려웠다.

머신러닝의 경우 통계적 특징 추출값에 대해 SVM 알고리즘을 적용하여 이진분류 모델과 다중 클래스 분류 모델을 구현하였다. 이진 분류 모델의 경우 데이터 셋 구성에 따른 차이는 있지만 83% 이상의 분류 정확도를 나타냈으며, 가장 높은 정확도는 SVM2로 90%의 정확도를 보였다. 반면, 다중 클래스 분류 문제의 경우 이진 분류 모델에 비해 현저히 낮은 66%의 정확도를 나타내었다. 이 같은 결과는 밸브의 구조적 특성에 기인한 것으로 혼동의 원인을 직관적으로 이해가 가능하였다. 다만, 밸브 누설에 대해서는 디스크 누설이 85%, 시트 누설이 93%로 이진 분류와 유사한 수준의 정확도가 얻어졌다. 따라서 SVM의 성능 개선을 위해 본 연구에

서 제시한 통계량 이외에 밸브 개도에 따라 구분 가능한 특징값을 추출할 수 있다면 밸브 누설 진단의 정확도가 더욱 향상될 것으로 보인다.

CNN 기반의 딥러닝의 경우, 다중 클래스 분류 문제에 있어 본 연구에서 적용한 계층의 단순함을 감안하더라도 하이퍼 파라미터의 조정 없이도 99.85%의 분류 정확도를 보였다. 결과적으로 딥러닝에 의한 밸브 내부 누설의 진단은 머신러닝에 의한 진단법에 비해 특징 추출과정 없이도 진단이 가능하다는 점과 높은 정확도를 고려한다면 더 적합한 접근 방법이라 판단된다. 다만, CNN의 우수한 성능에도 불구하고 알고리즘 특성 상 많은 양의 연산이 필요하므로 연산 속도를 향상하기 위한 추가 연구가 필요하다.

결론적으로 본 논문은 시간영역의 AE 원시 데이터를 기반으로 머신러닝과 딥러닝 사용 시 일정 수준의 진단 정확도가 확보되어 선박 배관계통 밸브로의 적용 가능성을 확인하였지만, 실적용을 위해서는 선박 및 기관실의 소음 및 진동 등 잡음에 대한 강건성을 확보해야 하므로 향후 이에 대한 추가 연구를 진행하고자 한다.

감사의 글

본 과제(결과물)는 교육부와 한국연구재단의 재원으로 지원을 받아 수행된 사회맞춤형 산학협력 선도대학(LINC+) 육성사업의 연구결과입니다.

References

- [1] Ahadi, M. and M. S. Bakhtiar(2010), Leak detection in water-filled plastic pipes through the application of tuned wavelet transforms to acoustic emission signals, *Applied Acoustics*, Vol. 71, No. 7, pp. 634-639.
- [2] Durgesh, K. S. and B. Lekha(2010), Data classification using support vector machine, *Journal of theoretical and applied information technology*, Vol. 12, No. 1, pp. 1-7.
- [3] Farquad, M. A. H. and I. Bose(2012), Preprocessing unbalanced data using support vector machine, *Decision Support Systems*, Vol. 53, No. 1, pp. 226-233.
- [4] Kim, J. H. and Y. G. Kim(2019), Development of IoT-based Safety Management Method through an Analysis of Risk Factors for Industrial Valves, *The Korean Institute of Gas*, Vol. 23, No. 5, pp. 35-43.
- [5] Lee, S. G., S. K. Park, J. H. Park, K. H. Kim, and Y. B. Kim(2007), Study on the Multi-measuring Method for Evaluation of Internal Leak of Power Plant Valve, *Journal of*

Power System Engineering, Vol. 11, No. 3, pp. 35-40.

- [6] Lei, Y., B. Yang, X. Jiang, F. Jia, N. Li, and A. K. Nandi (2020), Applications of machine learning to machine fault diagnosis: A review and roadmap, *Mechanical Systems and Signal Processing*, Vol. 138, 106587.
- [7] Li, Xiaoli(2002), A brief review: acoustic emission method for tool wear monitoring during turning, *International Journal of Machine Tools and Manufacture*, Vol. 42, No. 2, pp. 157-165.
- [8] Ozevin, D. and J. Harding(2012), Novel leak localization in pressurized pipeline networks using acoustic emission and geometric connectivity, *International Journal of Pressure Vessels and Piping*, Vol. 92, pp. 63-69.
- [9] Zhao, J., S. Yang, Q. Li, Y. Liu, X. Gu, and W. Liu(2021), A new bearing fault diagnosis method based on signal-to-image mapping and convolutional neural network, *Measurement*, Vol. 176, 109088.

Received : 2022. 02. 04.

Revised : 2022. 02. 21.

Accepted : 2022. 02. 25.