

머신러닝에 AE 신호를 적용하기 위한 Burst 신호 추출 및 특징개발 Burst Signal Extract and Features Analysis for using Acoustic Emission in Machine Learning

이정준* · 정덕영* · 박동희** · 최병근*†

Jeong-Jun Lee*, Deok-Young Cheong*, Dong-Hee Park** and
Byeong-Keun Choi*†

(Received 15 December 2022, Revision received 06 February 2023, Accepted 06 February 2023)

초록 : 음향방출 신호는 비파괴 검사 중 하나로 구조물, 파이프의 균열, 누수 등 미세한 결함을 감지하는데 사용된다. 내부의 변형 에너지가 방출하게 되면 Burst 신호가 발생하고 이는 결함의 특성을 지니고 있다. 하지만 현재에는 파이프나 구조물의 단일결함에 대한 분석에 관한 연구가 주로 수행되고 있으며 결함 상태를 분류하는 연구는 수행되지 않고 있다. 본 논문에서는 음향 방출 신호를 특징 기반 머신러닝에 적용하기 위한 방법에 대한 연구를 수행하였다. AE 신호의 특성을 분석하고 비주기적으로 나타나는 Burst 신호를 탐색하기 위해 포락처리 및 이동 제곱근 평균을 적용하였으며, 센서의 타입, 감도, 진단 대상의 재질 등에 따라 변화하는 임계값 기준을 에너지 비를 이용하여 Burst 신호를 추출하여 학습 데이터로 활용하였다. 특징기반 머신러닝에 적용하기 위해 Burst 신호의 특성을 고려하여 에너지와 시간, 형상적 특성 정보를 이용하여 특징을 개발하고 샤프스톱 과단 시험을 통해 분류 모델의 성능을 평가하였다.

키워드 : 음향방출, 특징기반 머신러닝, 돌발 신호 추출, 자동 임계값

Abstract : A burst signal is occurred when a defect appear in the acoustic emission signal. These could be classified according to features of the faults, but this has not been done at present. In this thesis, burst signal extraction and fault features were performed to apply signals of acoustic emission to feature based machine learning. In order to extract a burst signal, Envelope signal was used to Moving root mean square and a method of automatically searching for thresholds that change depending on the type, sensitivity, and target of sensor was developed. To apply the extracted burst signal to feature-based machine learning, feature analysis of the defect burst signal was investigated, and a research on Acoustic emission dedicated features was performed. Based on this method, it was confirmed that accuracy of machine learning was improved using Pencil lead break test about experimental data.

Key Words : Acoustic Emission, Features-based Machine Learning, Burst Signal Extraction, Automatic Threshold

* 최병근(<https://orcid.org/0000-0001-8912-3688>) : 교수,
경상국립대학교 에너지기계공학과

E-mail : bgchoi@gnu.ac.kr, Tel : 055-911-9525

*이정준(<https://orcid.org/0000-0002-7039-2412>), *정덕영(<https://orcid.org/0000-0002-6870-5811>) : 대학원생, 경상국립대학교 에너지기계공학과

**박동희(<https://orcid.org/0000-0001-5815-4545>) : 대표이사,
(주)다비스

*† Byeong-Keun Choi(<https://orcid.org/0000-0001-8912-3688>) :
Professor, Department of Energy Mechanical Engineering,
Gyeongsang National University.

E-mail : bgchoi@gnu.ac.kr, Tel : 055-911-9525

*Jeong-Jun Lee(<https://orcid.org/0000-0002-9827-4701>), *Deok-Young Cheong(<https://orcid.org/0000-0002-6870-5811>) : Graduate student, Department of Energy Mechanical Engineering, Gyeongsang National University.

**Dong-Hee Park(<https://orcid.org/0000-0001-5815-4545>) :
CEO, DAVISS.

1. 서론

AET(Acoustic Emission Test)는 비파괴 검사 중 하나로서, 대형 구조물이나 배관을 대상으로 균열(Crack), 누설(Leakage) 등과 같은 미세한 결함 탐지에 사용된다. 실시간으로 발생하는 시계열 데이터를 취득할 수 있어 발전시설, 플랜트 등 산업분야에 적용하여 실시간 상태감시에 사용되고 있다.¹⁾

현재 AET에 관련된 연구는 결함의 발생 거리에 따른 에너지 감쇠, 결함 성장에 따른 활성화도 분석, 발생원의 위치 표정 등 하나의 결함에 대한 분석에 사용되고 있다.²⁻⁴⁾ 하지만 AE 신호에 대해 결함의 상태를 분류하고 실시간으로 진단하는 방법에 관한 연구는 이루어지지 않고 있다. 이에 따라 각 결함의 상태를 나타내는 특징의 차이를 이용한 상태 분류에 관련된 연구가 필요하다.

최근 4차 산업 기술 개발이 이루어지면서 머신러닝(Machine learning), 딥-러닝(Deep learning), 데이터 처리 등의 기술을 설비 진단 분야에 적용하여 전문가의 부재중에도 실시간 진단을 수행하는 기술에 관한 연구가 활발히 수행되고 있다.^{5,6)} 지도 학습 중 하나인 특징기반 머신러닝 기술은 정상 및 결함 신호에 대한 특징을 바탕으로 학습모델을 생성하여 실시간으로 취득된 데이터의 결함 상태를 분류하여 진단한다. 따라서 AE 신호에서 결함의 상태에 따라 분류가 가능한 특징이 있다면, 머신러닝을 이용하여 실시간으로 AE신호를 이용한 설비의 결함 분류를 수행할 수 있다.

따라서 본 연구에서는 AE 신호를 특징기반 머신러닝에 적용하는 방법에 관한 연구를 수행하였다. AE 신호의 특성을 파악하여 특징기반 머신러닝에 적용하기 위한 고려사항들을 확인하고 결함에 의해 생성되는 Burst 신호 추출 및 분류가 가능한 AE 전용 특징에 관한 연구를 수행하였다. 개발된 방법의 검증을 위해 PLBT(Pencil Lead Break Test) 실험을 통해 AE 신호에서 발생하는 Burst 신호의 탐색 여부를 확인하고 특징기반 머신러닝에 적용하여 결함 특성에 따라 변화하는 분류 가능성에 관한 연구를 수행하였다.

2. 머신러닝 적용을 위한 특징 분석

2.1 AE 신호의 특징

AE 신호는 물체 내부에서 형성된 변형 에너지가 급격히 방출될 때 매질을 통해 전달되는 신호이며, 주파수 범위는 30 k~1 MHz 범위의 고주파 영역의 신호를 취득하여 미세한 균열이나 결함에서 발생하는 신호 분석을 수행한다.¹⁾ Fig. 1은 용접결함에 의해 발생된 AE 신호를 나타낸 그림이며,¹¹⁾ 잡음 성분이 있고 재료 내부에 변형이 발생하게 되면 μs 로 짧은 시간에 과도 형태의 신호가 발생하게 된다.⁷⁾ AE 신호의 특징을 Table 1과 같이 정리하였으며 분석하고자 하는 결함 대상에 따라 집중적으로 보는 특징이 다르며, 파형 및 주파수 분석, 활성화도 분석 등의 방법을 통해 결함 발생 여부, 손상된 정도 등을 확인하게 된다.^{1,8)}

Fig. 2는 분석에 사용되는 특징과 판단 기준을 나타낸 그림이며, 검출 임계값 이상이 되는 값을 이용하여 분석에 사용하게 된다.⁷⁾ 이 기준은 진단 대상의 재질, 센서 타입, 감도 등 취득 환경에 따라 변화하기 때문에 모니터링을 수행하여 잡음신




Fig. 1 AE signal




Fig. 2 Signal analysis of AE parameter

Table 1 Features of AE signal

Parameter	Unit
Counts	-
Duration	μs
Rise time	μs
Max peak	mV
Counts to peak	-
Root mean square(RMS)	mV
Average signal level(ASL)	dB
Average frequency	Hz
Reverberation frequency	Hz
Initiation frequency	Hz
Rise angle	rad
Decay angle	rad
Peak frequency	Hz
Frequency centroid	Hz

호의 3 dB 이상 또는 35 dB, 40 dB 등 특정 기준을 설정하여 분석을 수행하며 일관된 기준은 정립되어 있지 않다.^{8,9)} 이와 같이 사용자에게 따라 임계값의 기준이 바뀌기 때문에 결함 분류에 사용된 특징이 일관될 수 있도록 고려해야 한다.

2.2 특징기반 머신러닝

특징기반 머신러닝은 Fig. 3과 같은 과정을 통해 진단을 수행하게 된다. 학습 데이터에 정상 및 결함 등 상태에 대한 Labeling을 수행하여 특징 계산을 수행하며, 특징 선택, 분류 등 과정을 통해 학습모델을 생성하고 새롭게 취득된 신규 데이터가 학습된 모델에 입력하여 상태 진단을 수행하게 된다.¹⁰⁾ Fig. 4는 머신러닝에 대한 결과에 대한 예시이며, 사용된 특징을 바탕으로 공간을 구성하여 SVM을 통해 분류를 수행하게 된다. 각 학습된 데이터의 분류된 정도는 선택된 특징에 따라 군집된 밀도와 각 상태 간의 거리가 다르게 나타난다.

이에 따라, 특징 기반 머신러닝의 진단 정확도를 향상시키는 방법은 학습에 사용된 데이터의 양질 이외에도 결함 분류에 사용되는 특징들이다.

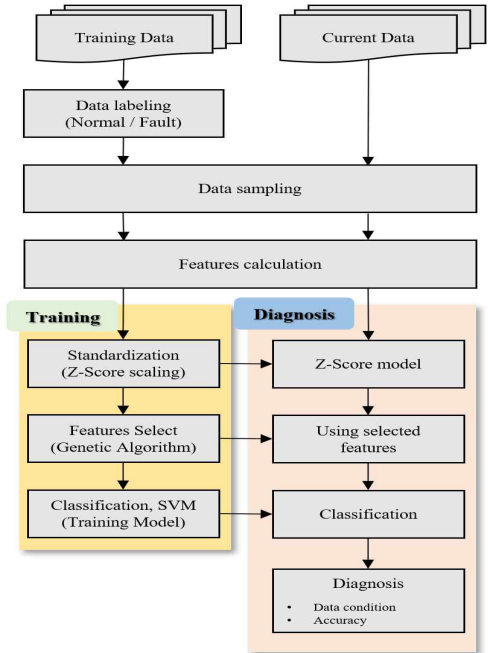


Fig. 3 Flow of features based machine learning

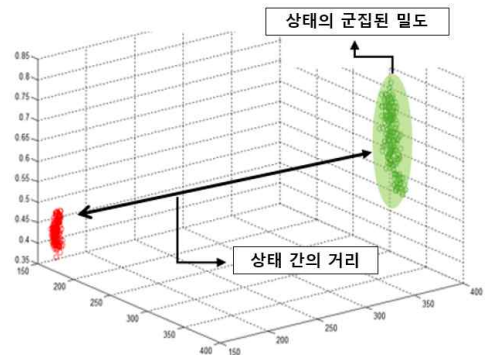


Fig. 4 Example of machine learning result

학습에 사용되는 특징들은 정상과 결함의 상태를 분류하는 핵심이 되기 때문에 학습하는 데이터의 특성을 고려하여 군집성을 이루고 상태 간 분류가 가능한 정보를 지닌 특징을 사용해야 한다.

2.3 AE 신호를 특징기반 머신러닝에 적용하기 위한 고려사항

회전체 설비의 학습데이터의 경우에는 주기적으로 발생하는 신호의 특성을 이용하여 일정 시

간 간격으로 분할하여 데이터양을 확보하여 머신러닝에 적용하게 된다.⁶⁾ 하지만 AE 신호의 경우에는 결함의 발생 또는 진전에 의해 Burst 신호가 발생하는데, 이는 비주기적인 신호이기 때문에 일정 간격으로 분할 시에는 Noise 부분의 신호만 학습될 수 있어 머신러닝의 분류성능이 낮아질 수 있다. 이러한 AE 신호를 특징 기반 머신러닝에 적용하기 위해서는 Burst 신호를 추출하여 특징 분류를 수행해야 한다.

3. AE 신호의 머신러닝 적용기술 개발

3.1 Burst 신호 추출 기술 개발

Burst 신호는 과도적인 신호가 발생한 후, 시간이 지남에 따라 감소하는 특징을 가지고 있으므로 과도 신호의 발생 여부와 지속된 시간을 고려해야 한다. 본 연구에서는 Burst 신호를 탐색하기 위해 포락처리(Envelope)를 수행한 후, Move RMS(Root Mean Square) 기법을 이용하여 탐색하였다. Fig. 5는 Burst 신호를 추출하기 위한 전체적인 흐름을 나타낸 그림이다.

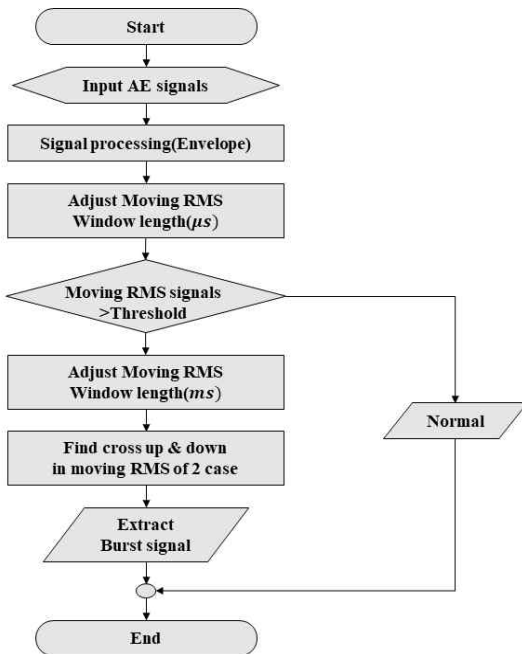


Fig. 5 Flow chart of extract burst signal

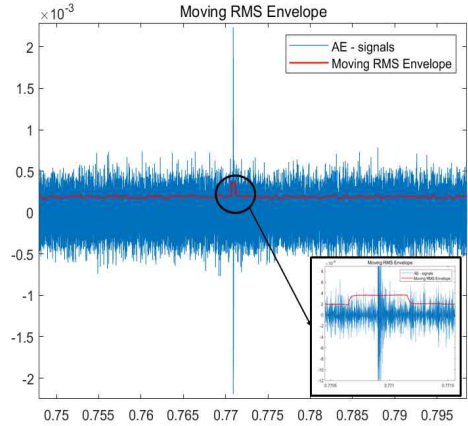


Fig. 6 Envelope processing & moving RMS

포락처리는 Rectification 과정이 있어 포락부 파형의 밀도를 높이기 때문에 Burst 신호 탐색에 유리한 강점이 있다. 하지만 단순 포락처리된 신호에서 Threshold를 기준 이상되는 값을 사용하게 되면 Burst 신호의 전체 길이가 아닌 최대 진폭 구간만 추출될 수 있다. 이러한 점을 고려하여 Envelope 처리 후 이동 RMS기법을 이용하였으며, 이는 Sliding window를 이용하여 전체 신호에 일정 간격의 Window가 이동하며 RMS 값을 계산하게 된다.

Fig. 6은 과도 신호를 탐색하기 위한 포락처리된 신호에 Moving RMS 기법을 적용한 결과를 나타낸 그림이다. Sliding window의 간격은 결함 발

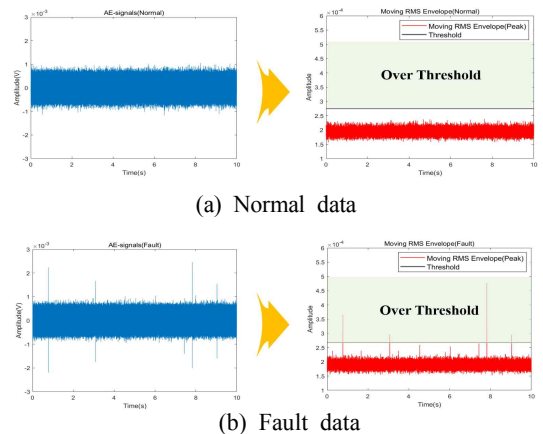


Fig. 7 Over threshold signals of moving RMS

생 시간과 Sampling frequency의 비를 이용하여 μs 단위로 설정하였으며, Burst 신호에는 잡음 진폭보다 높은 진폭이 분포되어 있어 탐색이 가능하다.

추출하기 위한 임계값 기준은 포락처리된 전체 신호에 대한 RMS 값이며, 이동 RMS 결과에 적용하여 임계값 이상 영역을 탐색하였다. 전체 신호에 대한 RMS 값은 Burst 신호보다 잡음성분이 많은 비중을 차지하기 때문에 Burst 구간의 RMS 값보다 낮게 나타나게 된다. 즉 취득된 신호의 잡음 에너지와 Peak 에너지의 비를 이용한 것이기 때문에 진폭의 크기와 상관없이 Burst 신호를 추출할 수 있게 된다. Fig. 7은 정상과 결함 데이터의 이동 RMS에 임계값 기준을 적용한 결과이며, Fig. 7(a)와 같이 정상 신호에서는 탐색이 되지 않고, Fig. 7(b)의 결함이 있는 신호의 경우에는 Burst 신호가 있는 영역에서 임계값 기준보다 높게 나타나게 된다.

지속시간을 고려하는 방법으로는 앞서 사용된 이동 RMS의 Sliding Window 간격을 ms 단위로 설정하였다. ms 간격은 μs 간격보다 잡음 성분이 많이 포함되기 때문에 다소 낮고 넓은 범위의 영역을 인식하게 된다. 이를 바탕으로 사용된 2가지 결과의 교차점을 탐색하여 Burst 신호를 추출하였다. Fig. 8은 전체적으로 수행되는 과정을 나타내었으며, 먼저 μs 단위의 Moving RMS에서 임계값의 기준이 넘는지 확인하고 교차되는 지점을 탐색하여 최종적으로 Burst 신호를 추출하게 된다.

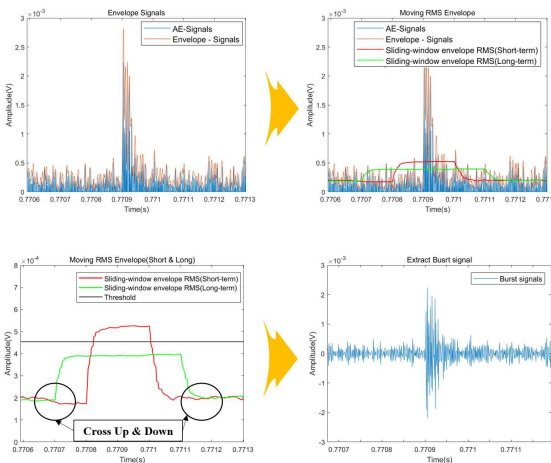


Fig. 8 Flow of extract burst signals

3.2 Burst 신호의 특징 개발

AE 신호 분석시 사용되는 특징은 최대 진폭, RMS, Count 수, 상승시간, 지속시간 등 진폭 크기 정보와 시간 정보와 관련된 값이다. 진폭의 크기와 관련된 특징은 진단 대상의 재질, 결함의 발생 위치 및 크기에 따라 변화할 수 있어 결함 분류에 변별성이 없을 수 있다. 또한 추출된 Burst 신호의 길이는 결함의 특성에 따라 다르기 때문에 에너지 크기와 Burst 신호의 길이를 고려한 특징이 사용되어야 한다.

Table 2 Specification of AE sensor

No.	Features
AE Parameter	
1	Counts
2	Duration
3	Rise time
4	Counts to peak
5	Average frequency
6	Reverberation frequency
7	Initiation frequency
8	Rise angle
9	Decay angle
10	Peak frequency
11	Frequency centroid
Developed features	
12	Counts/Duration
13	Counts to peak/Rise time
14	(Counts - Counts peak)/ (Duration - Rise time)
15	Max peak/Rise time
16	RMS/Duration
17	Mean/Duration
18	Impulse factor/Duration
19	Shape factor/Duration
20	Square mean root/Duration
20	Envelope RMS/Duration
21	Envelope Mean/Duration
22	Exponential Fitting Coefficient 1
23	Exponential Fitting Coefficient 2
24	Polynomial Fitting Coefficient 1
25	Polynomial Fitting Coefficient 2
26	Polynomial Fitting Coefficient 3

Statistical features	
27	Standard Deviation
28	Skewness
29	Kurtosis
30	Smoothness
31	Uniformity
Frequency features	
32	Frequency center
33	Mean square frequency
34	RMS frequency
35	Root variance frequency

본 연구에서는 일관된 특징을 사용하기 위해서 에너지 관련된 특징과 시간 정보의 비를 통해 새로운 특징을 개발하였다. 추출된 Burst 신호의 전체 길이와 관련된 AE Parameter는 진폭과 지속시간 비를 이용하고 최대 진폭과 관련된 특징은 상승시간 비를 활용하였다. 또한 지속적으로 감소하는 신호의 형상적 특징을 이용하여 Envelope 신호 처리를 수행한 후 지수, 2차 다항식 형태로 Fitting 되는 계수 값을 특징화 하였다. 이를 통해 Burst 신호의 진폭의 크기와 추출된 길이가 고려된 특징 11개, 형상적 정보를 나타내는 특징 5개를 개발하였다.

이 외에도 사용된 특징은 Table 1의 진폭과 관련 없는 11개의 특징과 통계적 특징 및 주파수 특징을 이용하여 Table 2와 같이 총 35개의 특징을 사용하였다.

4. 실험 및 적용 결과

4.1 Pencil Lead Break Test

개발된 Burst 신호의 추출방법과 특징을 사용하여 특징기반 머신러닝에 적용하여 분류 가능성을 확인하였다. AE센서의 성능을 평가하는 방법 중 하나인 PLBT(Pencil Lead Break Test)를 수행하여 데이터를 취득하였으며, 측정에 사용된 센서는 PAC(Physical Acoustic Corporation)사의 Wide band 형인 WDI-AST를 사용하였고, 사양과 취득 조건

은 Table 3에 나타내었다. Table 4는 실험의 각 Case를 나타내었으며, 판단되는 심의 재질과 두께 차이가 있는 Case로 선정하였다. Fig. 9는 실험 방법을 나타낸 그림이며, 가진원과 부착된 AE센서의 거리는 40 mm, 일정한 각도를 구현하기 위해 지지대를 활용하여 심 파단을 수행하였다.

Fig. 10의 좌측은 PLBT 실험에서 취득된 음향 방출 신호의 10개의 샘플을 나타내었으며, 우측의 그림은 하나의 샘플을 나타낸 그림이다. 신호의 파형을 비교한 결과, 진폭 크기의 경우 Case 1, Case 2는 유사하였으나 Case 3의 경우 약 10배 정도 차이 나는 것으로 확인된다. 진폭 크기를 제외한 파형의 형상은 각 Case별 육안으로는 비교하기 어려운 것으로 확인된다.

Table 3 Specification of sensor & acquisition condition

Specification of AE sensor	
Peak sensitivity [V/(m/s)]	96 dB
Operating frequency range	200 k~900 kHz
Directionality	± 1.5 dB
Temperature range	-35~75°C
Acquisition condition of AE data	
Sampling frequency	1 MHz
Recording time	60 sec
Acquisition fault data	40 sample

Table 4 Experiment case

Case	Type	Thickness	Hardness
1	Sharp lead	0.5 mm	2 B
2		1.3 mm	1 B
3	Color pencil	2.0 mm	-







Fig. 9 Experiment method of PLBT



(a) Result of lead break test (case 1)



(b) Result of lead break test (case 2)




(c) Result of lead break test (Case 3)


Fig. 10 AE signals of Each of PLBT

4.2 Burst signal 추출 결과

본 연구에서 개발한 Burst 신호 추출 방법을 적용한 결과를 Fig. 11에 나타내었다. Fig. 11(a)는 10개의 샘플에 대해 탐색한 결과를 나타낸 그림



(a) Result of extract burst signal(10 sample)



(b) Result of extend burst signal(1 sample)

Fig. 11 Result of extract burst signal

이며, 모두 탐색된 것으로 확인된다. Fig. 11(b)는 추출된 하나의 샘플을 나타낸 그림이며, 자동적으로 구간을 탐색하여 Burst 신호 길이만큼 추출된 것이 확인된다. 이 방법을 통해 별도의 임계값 기준 설정 없이 에너지 대 분포된 잡음 성분비를 이용하여 Burst 신호가 자동적으로 탐색이 가능한 것으로 확인된다.

4.3 특징기반 머신러닝 적용 결과

취득된 PLBT 데이터를 이용하여 특징기반 머신러닝에 적용하여 분류를 수행하였다. 확보된 샘플에서 2/3은 SVM(Support Vector Machine) 모델 학습에 사용하였으며, 1/3은 학습된 모델의 평가로 활용하였다. 사용된 특징은 Table 2와 같이 총 35개이며, 정규화를 수행하여 편향된 특징을 최소화 하였다. 특징 선택 시에는 GA(Genetic Algorithm)를 활용하여 각 Case의 군집된 밀도와 Case 간의 평균 거리를 비로 나타내어 최소가 되는 특징 3가지를 선택하도록 하였다.¹⁰⁾ Fig. 12는 특징 공간을 구성하여 SVM을 통해 분류를 수행한 결과이다. 선택된 특징은 Decay angle, Exponential Coefficient, Root variance Frequency로 3가지 특징이며, 분류 성능 결과는 100%로 확인된다. Case 3의 경우에는 Case 1, 2보다 Decay angle과 Exponential Coefficient에서 낮은 값을 가지는 것으로 확인되며, Case 1, 2는 Case 3과 비해 다소 거리가 가까우나 각 상태 간의 군집된 정도가 높아 각 Case별 분류가 되는 것으로 나타난다.

본 연구에서 개발된 방법에 대해 추가적인 비교를 수행하기 위해 참고문헌의 데이터 구성 방법과 특징을 사용하여 비교를 수행하였다.⁶⁾ Burst 신호를 추출한 것이 아닌 일정 간격으로 분할하여 학습데이터를 구성하고, 본 논문에서 사용된 특징 이외의 통계적, 형상적 정보를 가지는 Time domain(19개), Entropy domain(4개), Frequency domain(7개) 총 30개의 특징을 이용하여 분류 결과를 Fig. 13에 나타내었다. 분류 성능 결과는 72.56%이며, Case 3은 군집된 정도가 다소 높게 나타나지만 앞선 결과와 달리 Case 1, 2는 각 상태에 대한 군집을 이루지 않고 서로 혼동되어 분류가 되지 않는 것으로 확인된다.

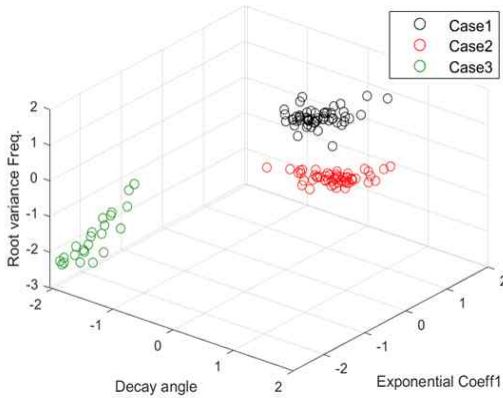


Fig. 12 Result of machine learning using developed method

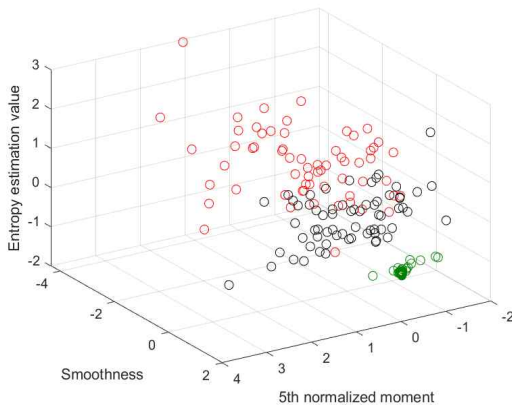


Fig. 13 Result of machine learning using ref[6] method

이는 잡음 성분이 포함되고 AE 신호에 대한 특징이 반영되지 않았기 때문에 사료된다.

5. 결론

본 연구에서는 특징기반 머신러닝에 AE 신호를 적용하기 위한 Burst 신호 추출 및 특징에 관한 연구를 수행하였다. AE 신호의 특성을 고려하여, 잡음성분을 제외한 Burst 신호만 추출하여 특징기반 머신러닝에 적용을 위한 학습데이터 신호를 생성하였다. 추출 방법으로 포락처리와 이동 RMS 기법을 사용하였으며, 개발된 방법으로 AE 신호에서 잡음 성분을 제외한 Burst 신호 구간이 추출되는 것을 확인하였다.

신호의 일관된 특징을 추출하기 위해 진폭 정보와 시간정보의 비를 활용하였으며, 또한 포락 처리된 신호의 형상적 정보를 이용하여 특징을 개발하였다. 개발된 추출방법 및 특징을 검증하기 위해 PLBT 실험 데이터를 수행하여 특징기반 머신러닝에 적용 및 검토하였다. 각 Case에 따라 분류가 되는 것으로 확인되었으며 머신러닝 분류성은 100%이다. 본 연구에서 제시한 Burst 신호 추출방법과 특징은 AE 신호를 특징기반 머신러닝에 적용 가능성을 확인하였다.

Author contributions

J. J. Lee & D. H. Park; Development Features, J. J. Lee & D.Y. Cheong; Data acquisition, J.J. Lee; Analysis signal, B. K. Choi; Formal analysis, Methodology, Project administration. J. J. Lee Writing-original draft. D. Y. Cheong; Writing-review & editing.

References

1. Y. S. Joo, S. H. Lim, H. S. Eom and J. H. Kim, 2003, "Acoustic Emission Technology and Application", Korea Atomic Energy Research Institute.
2. J. H. Kim, J. S. Kim, J. Lee, N. G. Kwag and B. Y. Lee, 2009, "The Basic Study on the Method of Acoustic Emission Signal Processing for the Failure Detection in the NPP Structures", Journal of the Korean Society for Nondestructive Testing, 29(5), 485-492.
3. F. W. Sebastian, B. Stefan and D. Söffker, 2019, "Experimental Results of Acoustic Emission Attenuation Due to Wave Propagation in Composites", Annual Conference of the Prognostics and Health Management Society, 11(1), 821. (<https://doi.org/10.36001/phmconf.2019.v11i1.821>)
4. Y. S. Lee, 2011, "Detection of Multiple Leak

- Locations in Underground Water Supply Pipes”, Korean Society for Noise and Vibration Engineering spring conference, 128-129.
5. K. R. Park et al., 2022, “Feature Analysis of Acoustic Emission Signals for Diagnosis of Loosened Bolt in Tubular Steel Tower”, Korean Society for Noise and Vibration Engineering, 32(2), 195-203.
(<https://doi.org/10.5050/KSNVE.2022.32.2.195>)
 6. D. Y. Cheong, B. H. Ahn, D. H. Park, H. J. Kim and B. K. Choi, 2019, “Feature-based Trend Monitoring of Vibration Signals According to Severity of Gear Tooth Breakage”, Korean Society for Noise and Vibration Engineering, 29(1), 199-205.
(<https://doi.org/10.5050/KSNVE.2019.29.2.199>)
 7. M. Ohtsu, 1995, “Acoustic Emission Theory for Moment Tensor Analysis”, Research in Nondestructive Evaluation, 6, 169-184.
 8. M. G. R. Sause, 2016, In Situ Monitoring of Fiber-Reinforced Composites, 242, Appendix.
 9. V. Barat et al., 2021, “Empirical Approach to Defect Detection Probability by Acoustic Emission Testing”, Applied Sciences, 11(20), 9429. (<https://doi.org/10.3390/app11209429>)
 10. H. T. Yu, T. H. Min, H. J. Kim, S. G. Kang and B. K. Choi, 2021, “Feature Analysis Based on Acoustic Emission Signal Processing for Tubular Steel Tower Condition Monitoring”, Korean Society for Noise and Vibration Engineering, 31(1), 195-202.
(DOI:10.5050/KSNVE.2021.31.2.195)