



저작자표시 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.
- 이차적 저작물을 작성할 수 있습니다.
- 이 저작물을 영리 목적으로 이용할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#) 

공 학 석 사 학 위 논 문

다중 센서 기반의 웨이블릿 변환과 CNN
딥러닝 모델을 이용한 산업 설비 고장진단에
관한 연구

A Study on Fault Diagnosis of Industrial Equipment
Using Multi-Sensor Based Wavelet Transform and CNN
Deep Learning Model

울 산 대 학 교 대 학 원

전기전자컴퓨터공학과

강 민 성

다중 센서 기반의 웨이블릿 변환과 CNN
딥러닝 모델을 이용한 산업 설비 고장진단에
관한 연구

지도교수 김종면

이 논문을 공학석사 학위논문으로 제출함




2024년 8월

울산대학교 대학원

전기전자컴퓨터공학과

강민성

강민성의 공학석사 학위논문을 인준함

심사위원장	권 영 근	
심사위원	김 중 면	
심사위원	조 동 식	

울 산 대 학 교 대 학 원

2024년 8월

[국문 요약]

다중 센서 기반의 웨이블릿 변환과 CNN 딥러닝 모델을 이용한 산업 설비 고장 진단 개발에 관한 연구

석유화학 산업 현장에서 주요 설비인 배관, 탱크, 교반기, 압축기는 현대산업의 핵심적인 시설물 중 하나이다. 고정 설비와 회전 설비를 구성하는 필수 요소 중 비교적 빈번하게 발생하는 결함은 부식, 크랙, 누출, 마모, 피로파괴 등이 있다. 이러한 결함들은 생산성 저하, 노후화로 인한 사고가 발생하는데, 조기 결함을 분석하여 사고를 방지하여야 한다. 하지만 산업 현장에서 설비의 상태를 확인하고 결함을 진단하는 과정은 전문적인 지식과 경험적 판단이 필요하다. 즉, 전문인력이 없는 상황에서 상태진단 및 결함 조기 감지는 불가능하다. 상태진단 전문가가 근무하지 않거나 상태 기반 정비를 운영하는 스마트팩토리의 회전설비 유지 및 안정성 확보를 위한 도구가 필요하다. 산업 현장에서 신호를 수집하고 자동으로 상태를 진단하여 결함 원인을 분류한다면 설비 유지관리에 큰 도움이 될 것이다.

P-F 곡선에 따르면, 결함이 발생한 초기 단계에서는 초음파 신호가 발생하고 결함이 진행됨에 따라 진동의 변화가 발생한다. 초음파 신호와 진동 신호를 분석하기 위해 다중 센서 기반의 고장 진단 장치를 개발하고, 장치 내부에 전처리 알고리즘과 딥러닝 네트워크 모델을 통해 결함을 분류하는 시스템을 제안한다. 이 시스템에서 제안하는 전처리 알고리즘에는 버터워스 주파수 대역 필터, 힐버트 변환, 로그 스케일 변환, 연속 웨이블릿 변환이 포함되는데, 이러한 전처리 알고리즘을 통해 최종적으로 시간-주파수-에너지 스펙트럼이 추출된다. 먼저, 버터워스 주파수 대역 필터는 신호의 불필요한 고주파나 저주파 성분을 제거하여 원하는 대역만을 통과시키는 역할을 하는데, 센서 제조사에서 제공된 동작 주파수 대역을 기반으로 필터를 적용하였다. 힐버트 변환은 실수부와 허수부를 이용하여 신호의 순간 진폭과 위상 정보를 추출하는 데 사용된다. 그리고 포락선 추출을 통해 배관 누출, 기어 결함, 베어링 결함에서 발생 되는 미세한 충격성 신호를 검출한다. 마지막으로, 연속 웨이블릿 변환을 통해 신호의 주파수 성분을 시간에 따라 다양한 스케일에서 분석하여 신호의 특정 패턴을 추출하였다. 이러한 전처리 과정을 거쳐 생성된 2차원 스펙트럼 이미지를 경량화 네트워크인 MobileNet CNN 모델의 입력으로 사용하여, 개발된 장치와 알고리즘을 검증하기 위해 다양한 환경을 모사한 테스트베드를 통해 검증하였다. 배관의 주요 결함인 누출과 크랙 분류 성능은 96.95%, 교반기의 주요 결함인 기어 결함, 베어링 결함, 임펠러 결함 분류 성능은 94.40%, 머시닝 센터 주요 결함인 기어결함, 베어링 결함, 공구 결함 분류 성능은 98.33%로 높은 결함 분류 성능을 보였다. 본 논문에서 개발한 고장진단 장치는 다중 센서 신호 측정과 결함 자동 분류는 전문 지식 없이도 산업 설비의 상태진단이 가능하도록 도움이 될 것이며 노후화로 인한 사고와 생산성 저하, 비용 손실을 방지하는데 기여할 것으로 예상된다.

주제어 : 고장진단, 진동 분석, 음향방출 분석, 다중 센서 신호처리, 웨이블릿 변환, CNN

목차

[국문 요약]	I
[목차]	II
[그림 목차]	IV
[표 목차]	IV
1. 서론	1
1.1 연구 목적 및 필요성	1
1.2 논문의 구성	1
2. 관련 연구	2
2.1 예방 정비	2
2.2 비파괴 검사 방법	3
2.2.1 음향방출 검사	3
2.2.2 진동 기반 분석	4
2.3 신호처리	7
2.3.1 힐버트 변환	7
2.3.2 연속 웨이블릿 변환	8
2.3.3 데시벨과 로그 스케일	11
3. 산업 설비 고장 진단 시스템	13
3.1 고장 진단 장치 HW 설계	13
3.1.1 센서 전원 공급 모듈 설계	14
3.1.2 센서 전원 공급 모듈 결과	15
3.2 고장 진단 SW 설계	16
3.3 고장 진단 알고리즘 설계	19
3.3.1 딥러닝 기반 고장 진단 결함 분류 모델	19
3.3.2 딥러닝 분류 모델 성능 평가 방법	22
4. 고장 진단 시스템 성능 검증	24
4.1 지하배관 결함모사 테스트베드 검증	24
4.2 화학 교반기 결함모사 테스트베드 검증	28
4.3 머시닝센터 결함모사 테스트베드 검증	33

5. 결론	38
참고 문헌	39
영문 요약	41

그림 차례

[그림 1] 산업 설비 유지보수 분류	2
[그림 2] 음향방출 검사의 Intensity 차트[2]	3
[그림 3] Acoustic Emission Signal Feature[3]	4
[그림 4] Vibration Severity Standard ISO 10816-1[8]	5
[그림 5] Prevention - Failure Curve	6
[그림 6] Analytic signal of the Envelope effect	8
[그림 7] 랜덤 노이즈가 포함된 주기 신호와 주파수 변환 결과	8
[그림 8] 다양한 주파수 분석 방법	9
[그림 9] Shapes of various mother wavelets	10
[그림 10] Wavelet Scaling	10
[그림 11] Wavelet Translation	10
[그림 12] 3차원 시간-주파수-에너지 스펙트럼 결과	11
[그림 13] 선형 스케일과 로그 스케일 비교	12
[그림 14] 배관 누출 신호 스케일 비교	12
[그림 15] 산업 설비 고장 진단 시스템 개요	13
[그림 16] 고장 진단 장치 하드웨어 구성도	13
[그림 17] 고장 진단 장치 하드웨어 디자인	14
[그림 18] 센서 전원 공급 모듈 구성도	14
[그림 19] 센서 전원 공급 모듈 필터 회로도	15
[그림 20] 스위칭 전원 공급 회로 설계도	15
[그림 21] 센서 전원 공급 모듈 아트웍 결과	16
[그림 22] 센서 전원 공급 모듈 최종 결과	16
[그림 23] 데이터 수집 프로그램 UI 구성	17
[그림 24] 고장 진단 및 결함 분류 알고리즘 순서도	17
[그림 25] 데이터 수집 프로그램 및 진단 알고리즘 통합 구조	18
[그림 26] 인공지능 모델 학습	18
[그림 27] MobileNet 딥러닝 네트워크 모델 구조	19
[그림 28] Depth-wise Separable Convolution 네트워크 구조	20
[그림 29] 일반적인 CNN Convolution 연산과의 비교[16]	21
[그림 30] CNN 모델의 입력 데이터 형태	22
[그림 31] 산업용 지하배관 결함모사 테스트베드	24
[그림 32] 산업용 지하배관 결함모사 테스트베드 도면	25
[그림 33] 데이터 수집 및 진단 절차 순서	26
[그림 34] 테스트베드 데이터 수집 절차	26
[그림 35] 지하배관 테스트베드 딥러닝 모델 학습 Confusion matrix 결과	27
[그림 36] 지하배관 테스트베드 상태 분류 및 모델 성능 검증	27
[그림 37] 산업용 화학 교반기 기본 구조	28
[그림 38] 산업용 화학 교반기 결함모사 테스트베드	29
[그림 39] 기어 박스 내부 구조 및 센서 설치 위치	29

[그림 40] 교반기 테스트베드 딥러닝 모델 학습 Confusion matrix 결과	31
[그림 41] 교반기 테스트베드 상태 분류 및 모델 성능 검증	31
[그림 42] 공작기계 결함모사 테스트베드	33
[그림 43] 머시닝센터 테스트베드 Confusion matrix 결과 1	34
[그림 44] 다중 채널 기반 CNN 모델 구성도	35
[그림 45] 머시닝센터 테스트베드 Confusion matrix 결과 2	35
[그림 46] 머시닝센터 테스트베드 상태 분류 및 모델 성능 검증	36

표 목차

[표 1] 진동 및 음향방출을 활용한 회전 설비 분석 장단점	6
[표 2] MobileNet 네트워크 모델의 기본 구조	21
[표 3] Confusion Matrix 4가지 Condition	22
[표 4] Confusion Matrix를 이용한 대표적인 성능지표	23
[표 5] 실험에 사용된 테스트베드 정보	25
[표 6] 지하배관 결함모사 테스트베드 전처리 파라미터	26
[표 7] 교반기 결함모사 테스트베드 기본 정보	30
[표 8] 교반기 결함모사 테스트베드 전처리 파라미터	30
[표 9] 머시닝센터 결함모사 테스트베드 전처리 파라미터	33

1. 서론

1.1 연구 목적 및 필요성

현대 산업에서 설비의 노후화는 다양한 위험과 비용 손실을 수반하는 심각한 문제를 초래한다. 특히, 석유화학 산업에서는 배관, 탱크, 교반기, 압축기 등의 주요 설비가 시간의 경과에 따라 피로, 부식, 균열 등의 구조적 결함이 나타난다. 이러한 결함은 설비의 안전성과 성능에 직접적인 영향을 미치며, 심각한 경우 대규모 고장이나 사고로 이어질 수 있다. 또한, 노후화된 설비는 에너지 효율이 낮아져 운영 비용 상승과 생산성 저하를 유발한다.

기존에는 예방 정비와 사후 정비를 통해 설비의 상태를 진단하지만, 설비나 결함에 대한 지식이 부족하여 사후 정비에 의존하는 경우가 많다. 사후 정비는 설비가 고장난 후에 진행되므로 예기치 않은 설비 중단과 생산성 저하, 비용 손실을 초래한다. 반면, 예방 정비는 설비 고장을 미연에 방지하는 방법으로 시간 기반 정비와 상태 기반 정비로 나뉜다. 특히, 상태 기반 정비는 설비 상태 모니터링을 통해 이상 유무를 진단하고, 고장 시기를 예지하여 수리 시기를 결정한다. 이를 위해 다양한 비파괴 검사 방법, 데이터 가공, 디지털트윈, 인공지능을 활용한다.

Nowlan과 Heap이 제안한 P-F 곡선에 따르면, 결함 발생 후 초음파 영역의 에너지 신호가 발생하고, 그 후 진동 신호를 통해 상태를 파악할 수 있다. 배관 누출, 기어 결함, 베어링 결함들은 결함 발생 시 충격성 신호를 발생시키며, 기존의 결함 진단 방법으로는 시간 파형 패턴 분석이나 주파수 분석이 사용된다. 하지만 다양한 노이즈가 많은 환경에서는 결함 분석이 쉽지 않아 전처리 과정이 필요하다. 본 연구에서는 조기 결함 및 설비 상태를 진단하기 위해서 음향방출 검사와 진동 분석을 활용하고자 한다.

본 연구에서는 다중 센서 기반의 고장 진단 장치를 제안하고, 양질의 데이터 취득을 위해 힐버트 변환, 웨이블릿 변환 등 전처리 알고리즘을 이용하여 데이터를 가공하고, 경량화된 인공지능 모델을 통해 설비 상태를 모니터링하고 결함을 분류하는 시스템을 제안한다. 또한, 산업 설비를 모사한 결함 모사 테스트베드를 통해 시스템의 성능을 검증한다. 이 시스템은 설비의 조기 결함 진단과 상태 모니터링을 가능하게 하여 설비의 안전성을 높이고, 유지보수 비용을 절감하며, 생산성을 향상시킬 수 있을 것으로 기대된다.

1.2 논문의 구성

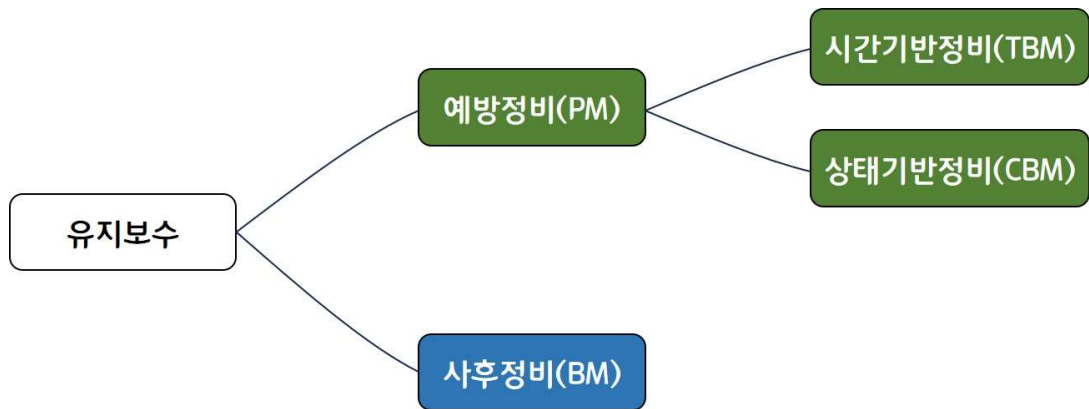
본 논문은 다음과 같이 구성되어 있다. 2장에서는 예방 정비, 기존 비파괴 검사 방법, 신호처리 방법에 대한 관련 연구를 서술하고, 3장에서는 산업 설비 고장 진단 시스템 설계에 대해 기술한다. 4장에서는 산업 설비를 모사한 결함모사 테스트베드를 이용하여 장치와 알고리즘을 검증하고, 실험 결과 및 분석 내용에 대해 소개한다. 마지막으로 5장에서는 본 논문의 결론을 맺는다.

2. 관련 연구

산업 설비의 고장진단 연구는 시간이 지남에 따라 상당한 발전을 이루었다. 초기에는 주로 시각적 검사나 청음 검사와 같은 기본적인 방법들이 사용되었으나, 이러한 방법들은 전문가의 경험에 크게 의존하는 한계가 존재하였다. 기술의 발전과 함께 방사선 투과 검사, 초음파 탐상 검사, 와전류 탐상 검사, 열화상 등과 같은 비파괴 검사들이 도입되어 보다 정밀한 진단이 가능해졌다. 컴퓨터 기술이 발전해 오면서 데이터 분석, 패턴 인식, 통계적 방법론을 통해 고장진단을 하였다. 이는 고장의 원인 분석과 예측에 중요한 기여를 하였고, 최근에는 인공지능을 통해 설비를 진단하며, 빅데이터를 통해 복잡한 패턴을 학습하여 결함의 조기 진단에 사용되고 있다.

2.1 예방 정비

예방 정비는 설비의 신뢰성을 높이고, 예기치 않은 고장을 방지하기 위해 정기적으로 수행하는 유지보수 방법이다. 이 과정은 정기적인 검사, 부품 교체 및 조정을 포함하여, 설비의 수명을 연장하고 운영 비용을 절감하는 데 목적이 있다. 예방 정비는 온, 오프라인으로 장비의 상태를 모니터링하여 잠재적 문제를 조기에 발견하고 대응함으로써, 설비의 성능과 안전성을 유지한다. 이는 장기적으로 비용을 절감하고, 생산성을 향상시키는 중요한 전략으로 다양한 산업 현장에서 필수이다[1].



[그림 1] 산업 설비 유지보수 분류

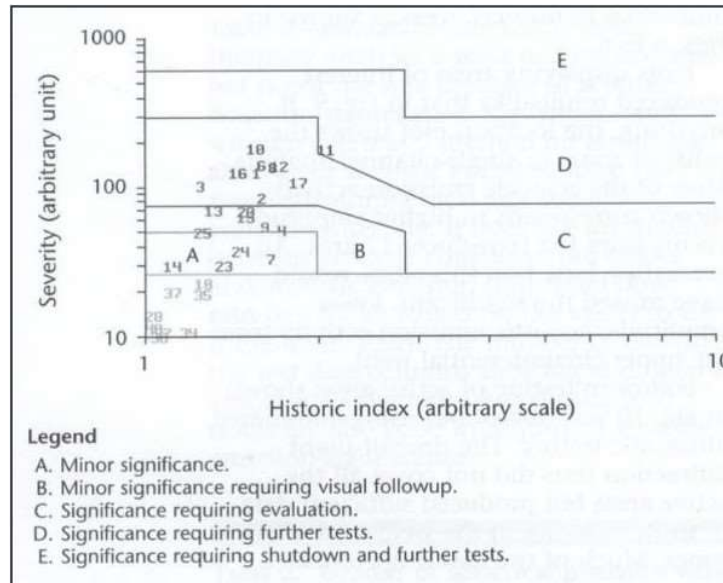
시간 기반 정비는 특정 시간 주기나 사용 시간에 기반하여 정기적인 유지보수를 수행하는 방식으로, 예측 가능하고 일관된 유지보수를 제공한다. 그러나 이 방법은 설비의 실제 필요성과 관계없이 일정에 따라 유지보수를 수행하므로, 때때로 불필요한 유지보수를 수행한다. 상태 기반 정비는 설비의 실제 운영 상태와 성능을 실시간으로 모니터링하여 유지보수 필요성을 판단하는 방식으로, 불필요한 유지보수를 줄이고 효율성을 증가시킬 수 있지만, 상태 모니터링 시스템의 설치와 유지관리에 추가적인 비용과 노력이 필요하다. 기존에는 전문가에 의존한 유지보수를 진행하였다면, 근래에는 빅데이터, 인공지능 기반의 확장된 개념의 상태 기반 정비 기술 연구가 활발히 진행되고 있다.

2.2 비파괴 검사 방법

비파괴 검사는 대상을 파괴하지 않고 대상에 존재하는 결함 또는 불연속을 판단하는 기술이다. 여러 비파괴 검사들이 있지만, 본 연구에서는 넓은 범위와 간접적으로 신호 수집이 가능한 음향방출 검사와 진동 기반 분석을 활용하였다.

2.2.1 음향방출 검사

음향방출 검사(Acoustic Emission Testing, AET)는 구조물이나 재료가 변형될 때 발생하는 탄성파를 감지하여 결함이나 손상의 크기와 위치를 파악하는 검사이다. 구조물 변형이 일어날 때 탄성파 에너지가 Impulse 신호로 발산하고, 이러한 신호를 감지하여 결함 탐지 및 결함 위치 추정 등의 구조물의 건진성 검사를 수행할 수 있다. 그림 2는 미국 비파괴 검사협회인 ASNT(The American Society For Nondestructive Testing)에서 제안한 음향방출의 특정 사건이나 결함의 심각도를 나타내는 차트이다. 이를 통해서 검사 대상체의 건진성을 평가하는 기준이 되는데, 음향방출 신호를 감지하여 각 이벤트 심각도(Severity)와 발생 빈도(Historic Index)를 기록한다. 심각도는 음향방출의 크기나 에너지로 나타내며, Historic Index는 이벤트의 누적 발생 횟수로 나타낸다[2].



[그림 2] 음향방출 검사의 Intensity 차트[2]


Historic Index는 모든 이벤트의 평균 신호 강도에 대한 이벤트의 평균 신호 강도의 비율로 표현된다. 심각도는 신호 강도의 수치 값이 가장 큰 10개 이벤트의 평균이다.

$$HistoricIndex = \frac{M\text{개의 가장 최근 Hit 에너지의 평균}}{\text{전체 Hit 에너지의 평균}}, \quad (1)$$

$M = \text{전체 Hit 수의 } 20\%$

$$Severity = \frac{1}{10} \sum_{i=1}^{i=10} S_{0i} \quad (2)$$

Historic Index는 모든 이벤트의 평균 신호 강도에 대한 이벤트의 평균 신호 강도의 비율로 표현된다. 심각도는 신호 강도의 수치 값이 가장 큰 10개 이벤트의 평균이다.




[그림 3] Acoustic Emission Signal Feature[3]

음향방출 신호의 특징들은 Amplitude, Energy, Duration, Risetime 등이 있다. 기존 방법들은 임계치를 설정하여 임계치를 벗어나면 Hit 검출을 한다[3]. 다만, 이러한 임계치 설정의 경우에 주변 환경이나, 전문가의 경험이 뒷받침되어야 하기에 누구나 사용기에 어려운 분야이다. 지하배관의 상태 진단을 위해 음향방출 검사가 사용되기도 한다. 데이터 기반 패턴 인식이나, 누출이 발생한 거리 추정에도 사용되고 있다[4]. 공작기계의 상태 감시 및 진단을 위해 음향방출 신호의 주파수 분석 연구도 활발히 진행되고 있다[5]. 음향방출 센서를 활용한 결함 감지는 웨이블릿 패킷, 힐버트 변환, 자기 상관 함수 등을 합한 신호처리 알고리즘을 이용하여 노이즈 제거 및 베어링과 기어 박스 결함을 분석에 활용한 연구에 따르면 조기 결함을 감지에 우수한 성능을 보여주었다[6].

2.2.2 진동 기반 분석

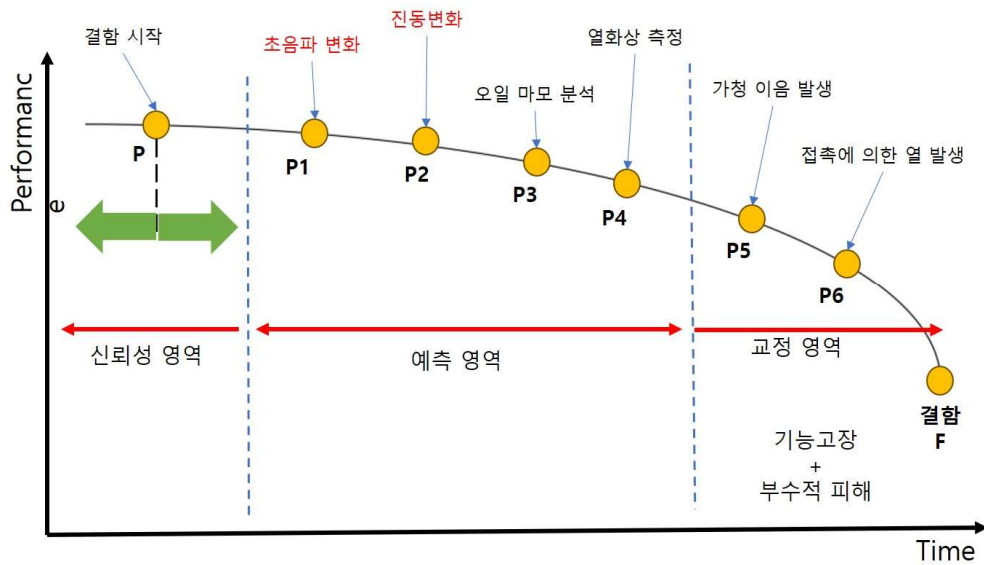
진동 분석(Vibration Analysis)은 주로 기계적 결함을 진단하는데 사용된다. 시간/주파수 분석, 궤적/위상 분석 등 분석 방법들이 여러 가지가 존재한다. 진동의 주파수를 분석하여 결함의 원인을 직접적으로 분석한다[7]. 기계적 결함의 주요 결함으로는 불평형, 축 정렬 불량, 베어링 결함, 기어 결함 등이 있으며, 각각은 특정 진동 패턴과 결함 주파수 특징을 통해 식별된다. 예를 들어 베어링 결함은 고주파수 진동 증가로, 불평형은 저주파수 영역에서 큰 진동으로, 축 정렬 불량은 특정 주파수에서의 진동 변화로, 기어 결함은 기어 맞물림 주파수와 같은 결함 주파수에서 진동 증가로 나타난다. ISO 10816-1은 비회전 설비에서 수

행된 측정된 진동 신호를 기반으로 진동 평가 절차를 설명하는 일반적인 지침서이다. 소형 모터, 중형 모터, 발전기, 증기 및 가스 터빈, 압축기, 펌프 및 팬 등이 있다. ISO 10816 기반의 진동 평가 방법은 설비의 정상과 비정상을 구분할 수는 있으나, 결함 원인에 대해서는 분석이 어렵다. 이러한 문제점을 해소하기 위하여 스펙트럼 분석을 통해 설비의 결함 원인을 찾아야한다. 스펙트럼 분석을 통해 설비의 정상 작동 시 발생하는 진동과 결함 발생 시 나타나는 진동 패턴을 비교 분석할 수 있다. 이를 통해 설비의 이상 징후를 조기에 발견하고 결함을 예측하여 사전에 대응할 수 있다.



[그림 4] Vibration Severity Standard ISO 10816-1[8]

결함이 발생하는 단계에서 가장 먼저 20kHz 이상의 초음파 영역의 신호가 변환된다. 초음파는 높은 주파수의 진동 신호로 결함이 진전됨에 따라 저주파의 진동 신호로 변화되고, 온도의 증가는 결함의 마지막 단계에서 검출되며 수리가 필요한 단계이다. P-F 커브에 나타나듯이 가장 먼저 초음파 신호가 변화하고 진동 신호가 발생한다[9]. 이 곡선은 설비의 수명 주기의 여러 단계를 보여주며, 사전 예방 단계부터 결함이 발견되는 시점까지 검사 방법을 통해 장비의 상태를 파악할 수 있는 시기를 보여준다. 조기 결함 신호는 초음파 영역에서 나타나고, 다음으로 진동의 변화가 발생한다. 그러므로 음향방출과 진동 신호를 동시에 분석 가능한 시스템이 필요하다.



[그림 5] Prevention - Failure Curve

진동 분석은 모터, 펌프, 팬, 블레이드, 기어 박스 등과 같은 회전 기계의 마모, 정렬 불량, 불균형, 베어링 결함 등을 감지하는데 일반적으로 사용된다. 이와 달리, 음향방출 시험은 비파괴 검사 기법이며, 재료 내부의 변형으로 발생하는 고주파 탄성파를 측정한다. 주로 파이프, 압력 용기, 밸브, 탱크와 같은 설비에서 주로 모니터링하는데 사용한다. 환경 및 목적에 따라 검사 방법을 설정하는 것이 중요하며, 회전 기계의 상태를 모니터링하는데 아래 표 1에서처럼 장단점을 가지고 있다. 두 가지 설비 검사 방법을 적절히 응용하고 활용해야 한다[10].

구분	진동 분석	음향방출 검사
측정 방법	회전 설비 표면의 기계적 진동을 측정 (예시: 모터, 펌프, 기어박스)	재료 내부 구조의 변화에 의해 방출되는 탄성파를 측정 (예시: 펌프, 밸브, 압력 용기, 배관)
주파수	회전 속도에 따라 보통 20kHz 이하	20kHz ~ 1MHz 사이의 초음파 스펙트럼
설치 방법	설비 표면	설비 표면
결함 감지	결함이 심각해질 때까지, 신호가 크게 변하지 않을 수 있음, 초기 불연속 신호에 대한 민감도가 제한됨	초기 불연속 신호에 대한 민감도가 높음

[표 1] 진동 및 음향방출을 활용한 회전 설비 분석 장단점

음향방출 검사 방법이 결함의 신호 변화에 더 민감하게 반응하며, 진동 분석 방법보다 초기 결함 탐지에 더 효과적이다[11]. 저속의 회전 설비에 대해서는 진동 신호가 약하기 때문에 진동 분석 방법은 한계가 있으나, 음향방출 검사의 경우 저속에서도 베어링의 충격 신호를 식별할 수 있다. 위에서 살펴본 것 같이, 두 가지 방법 모두 장, 단점을 보여주기 때문에, 서로 상호 보완적인 도구로 사용해야 한다.

2.3 신호처리

설비에 부착된 센서를 통해 얻은 데이터는 주변 환경에 의한 잡음을 포함하고 있다. 이로 인해 상태 분석에 어려움을 주기 때문에, 신호처리를 통해 잡음을 제거하고 양질의 데이터로 만드는 과정은 필수이다. 이는 분석의 정확도와 신뢰성을 향상시키는데 매우 중요하다. 또한, 효과적인 결함 탐지와 진단을 위해서는 단순히 잡음만 제거하는 것이 아닌 데이터에서 유용한 특징들을 추출하는 것이 필요하다. 추출된 특징들을 통해 이상치 감지 및 결함분류를 할 수 있다.

2.3.1 힐버트 변환

힐버트 변환(Hilbert Transform) 신호처리에서 중요한 도구로, 실수 신호를 복소 신호로 변환하여 신호의 진폭과 위상 정보를 얻는 데 사용된다. 힐버트 변환은 하나의 선형 필터로써 신호의 진폭은 유지하면서, 위상을 90° 만큼 Shift 한 것이다[10, 11]. 어떤 신호를 $x(t)$ 라 할 때, 힐버트 변환된 신호를 $\hat{x}(t)$ 라 할 때, 다음과 같은 수식으로 표현할 수 있다.


$$H(t) = x(t) + j\hat{x}(t) \quad (3)$$

힐버트 변환은 순간적인 변화를 분석하는 데 효과적이고, 신호의 세부적인 동적 변화를 파악할 수 있다. 그리고 힐버트 변환을 이용한 포락선 추출은 신호의 순간적인 진폭 변화를 추적함으로써, 신호의 동적 특성을 분석할 수 있다. 포락 처리된 신호로 원신호에서 나타나는 시간에 따른 진폭 변화가 발생 되는 주파수를 분별할 수 있고, 저주파수로 변조된다.

$$\text{순간 진폭} = |H(t)| = \sqrt{x^2(t) + \hat{x}^2(t)} \quad (4)$$

$$\text{순간 위상} = \angle H(t) = \tan^{-1} \frac{\hat{x}(t)}{x(t)} \quad (5)$$


힐버트 변환을 이용한 포락선을 추출하여 기어 결함, 베어링 결함에서 발생 되는 미세한 충격파를 검출하는데 유용하다[12~14].



[그림 6] Analytic signal of the Envelope effect


2.3.2 연속 웨이블릿 변환

푸리에 변환은 데이터 주파수 스펙트럼을 분석할 수 있는 도구이지만, 시간 또는 공간에 국한되지 않은 Sin 파형의 합으로 표현된다. 하지만, 푸리에 변환은 전체 시간에 대한 주파수 분석을 통해 갑작스러운 신호의 변화를 효율적으로 나타낼 수 없다.



[그림 7] 랜덤 노이즈가 포함된 주기 신호와 주파수 변환 결과

이를 보완하기 위한 목적으로 시간-주파수 분석이 필요하다[15]. 푸리에 변환의 문제를 해결하기 위해 단시간 푸리에 변환과 연속 웨이블릿 변환이 제안되었다. 단시간 푸리에 변환은 푸리에 변환의 문제점인 시간에 대한 변화를 고려하기 위해 고안된 방법이다. 시간, 주파수, 진폭의 정보를 얻을 수 있어 특정 시점의 주파수 성분을 알 수 있다. 하지만, 단시간 푸리에 변환은 Window 크기에 따라 주파수 해상도나 시간 해상도를 변화된다. 데이터 분석 목적에 맞도록 Window 크기를 조절해야 하는 문제가 있다.



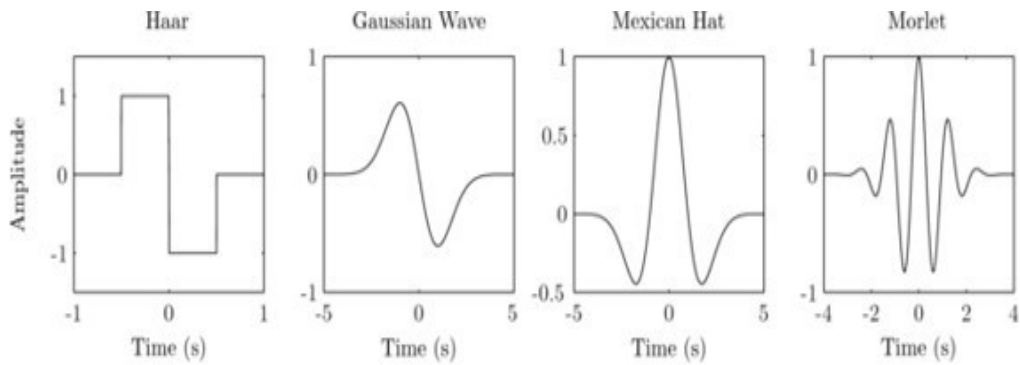
[그림 8] 다양한 주파수 분석 방법

시간과 주파수 해상도 모두 필요한 경우에는 연속 웨이블릿 변환이 좋은 대안이 될 수 있다[16]. 연속 웨이블릿 변환은 미리 정의된 웨이블릿 함수에 따라 광범위한 분석이 될 수 있다. 연속 웨이블릿 변환 공식은 다음과 같다.

$$CWT_{(\tau, s)} = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-\tau}{s} \right) dt, \quad (6)$$

τ 와 s 는 각각 Wavelet의 Translation과 Scale을 나타내는 지표이며, 웨이블릿 변환은 웨이블릿 함수를 시간 축 방향으로 이동시키며 원본 신호 $x(t)$ 의 상관계수를 계산하고, 웨이블릿의 Scale을 조정하여 다시 시간 축 방향으로 이동시키며, 상관계수를 계산하는 과정을 반복한다. 연속 웨이블릿 변환은 다음과 같은 단계로 수행된다.

1. 첫 번째로 분석할 신호의 특성에 적합한 웨이블릿 함수를 선택해야 한다. 다양한 웨이블릿 함수가 있으며, 웨이블릿 함수를 선택하는 것에 따라 분석 결과가 달라진다. 이번 연구에서는 Mexican hat 함수와 Morlet 함수를 사용하였다. 각각 다른 특성이 있으며, Mexican hat 함수는 시간 도메인 상에서의 신호 변화를 잘 감지한다. 그리고 Morlet 함수는 주파수 분석 및 스펙트럼을 해석하는 경우 주로 사용되는 함수이다[17].




[그림 9] Shapes of various mother wavelets

2. 웨이블릿 함수를 통해 신호를 여러 Scale로 변환하면서 시간 축에 따라 분석한다. 연속 웨이블릿 함수는 웨이블릿 함수를 신호에 대해 Scaling(확대 또는 축소)하고 Translation(이동) 하면서 분석한다. Low Scale은 웨이블릿 함수를 축소 시킨 형태이며, 고주파와 같은 급변하는 신호를 분석하고, High Scale은 웨이블릿 함수를 확대한 형태로써, 저주파와 같은 천천히 변화하는 신호를 분석할 수 있다.




[그림 10] Wavelet Scaling



[그림 11] Wavelet Translation

3. 연속 웨이블릿 변환 후 얻은 계수 값을 이용하여 3차원 스펙트럼인 Scalogram으로 나타낼 수 있다. Scalogram은 시간과 주파수(Scale)에 따른 웨이블릿 계수의 크기를 색상 또는 밝기로 나타내는 3차원 이미지로 시각화하는 분석 방법이다. 이를 통해 신호의 시간에 따른 주파수 변화를 직관적으로 파악할 수 있다.



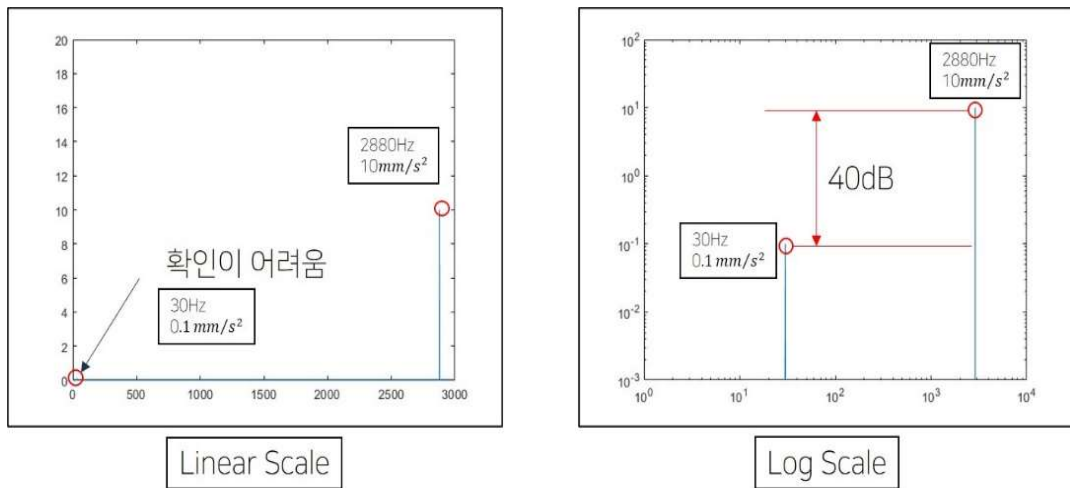
[그림 12] 3차원 시간-주파수-에너지 스펙트럼 결과

2.3.3 데시벨과 로그 스케일

Decibel(dB)은 공학 분야, 특히 전기 전자, 통신 분야에서 사용되는 단위이다. Decibel은 신호의 강도나 전력 수준을 로그 스케일로 표현한 단위이다. 원론적 의미로는 기존 에너지에 대한 현재 에너지의 비율을 의미한다.


$$Decibel = 20\log_{10}\frac{p}{p_0} [dB], (7)$$

이번 연구에서 사용된 연속 웨이블릿 변화를 사용하면, 특정 신호의 에너지가 매우 클 때, 상대적으로 작은 신호들이 보이지 않는다. 이러한 현상은 신호처리에서 종종 발생하는 문제인데, 넓은 영역에서 선형 스케일은 에너지의 변화율에 대해서는 볼 수 없다. 이러한 문제를 해결하기 위해 로그 스케일을 적용하여 동적 범위를 축소 시키고, 큰 에너지가 발생하여도 작은 에너지를 분석 가능하다.



[그림 13] 선형 스케일과 로그 스케일 비교

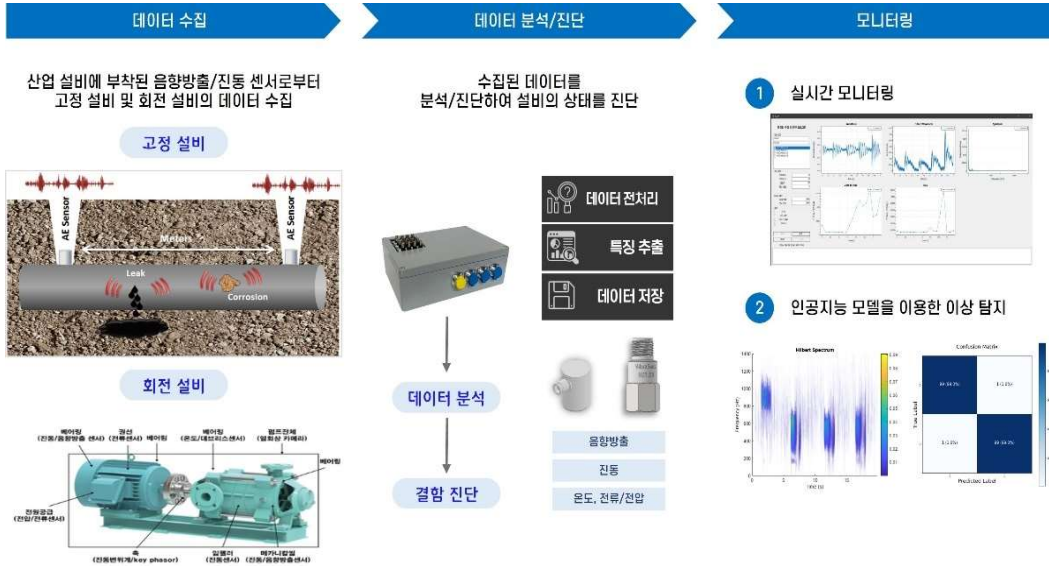
그림 11처럼 갑작스러운 큰 값이 입력되었을 때, 작은 값들의 변화는 확인이 어렵다. 로그 스케일을 적용한다면 작은 값부터 큰 값까지 전체적인 에너지의 변화율을 확인할 수 있다. 로그 스케일을 적용하는 이유는 이미지 처리를 효율적으로 확인하기 위해서다. 아래 그림은 배관에서 누출 신호가 발생하였을 때, 음향방출 센서로 탄성과 에너지를 취득한 1초 데이터로 0.3초 경부터 누출이 진행되고 있으나, 선형 스케일에서는 누출 신호가 확인이 어렵고 로그 스케일로 변환한 데이터는 확인이 가능하였다.



[그림 14] 배관 누출 신호 스케일 비교

3. 산업 설비 고장 진단 시스템

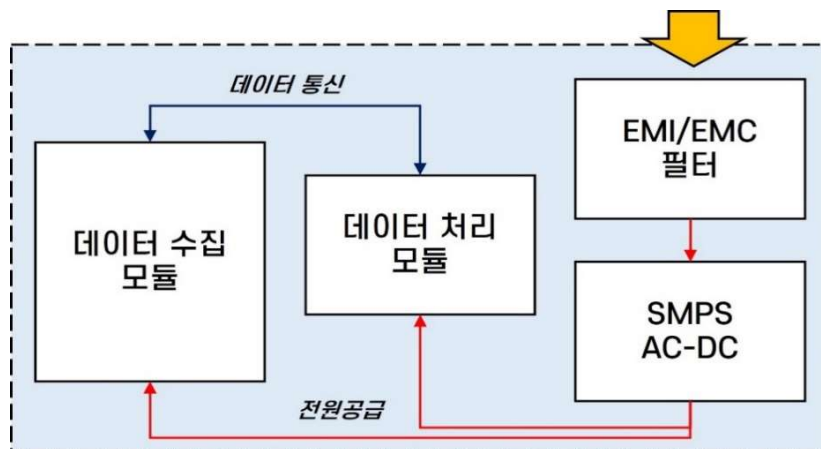
본 연구에서는 설비에 부착된 센서를 통해 실시간 데이터를 취득하고, 전처리 과정을 통해 신호의 패턴을 분석하여 설비의 결함을 분류하는 것이 최종 목표이다.



[그림 15] 산업 설비 고장 진단 시스템 개요

3.1 고장 진단 장치 HW 설계

고장 진단 장치는 범용성, 안정성, 편의성을 고려하여 제작하였다. 음향방출 센서와 진동 가속도 센서를 동시에 취득하기 위해서는 그에 맞는 DAQ가 필요한데, 안정적으로 사용하기 위해 National Instruments 사의 DAQ와 Chassis를 선정하였다. 다중 센서 기반의 고장 진단 장치의 구성도는 아래 그림 14와 같다.



[그림 16] 고장 진단 장치 하드웨어 구성도

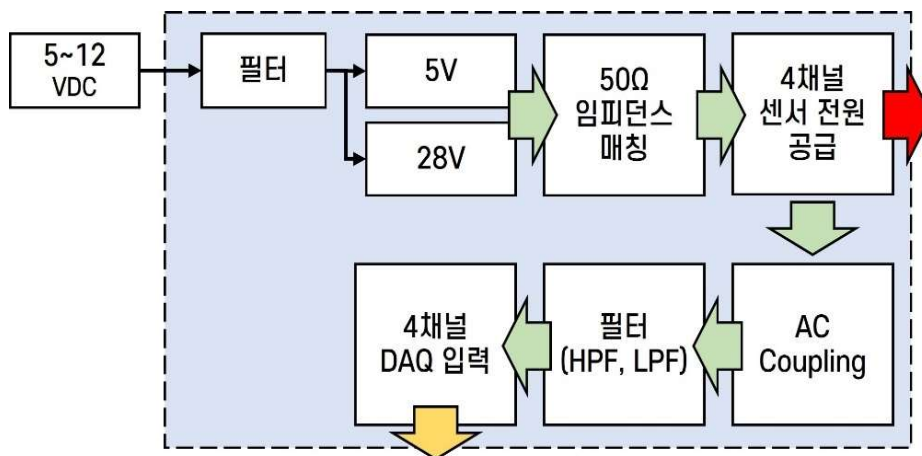


[그림 17] 고장 진단 장치 하드웨어 디자인

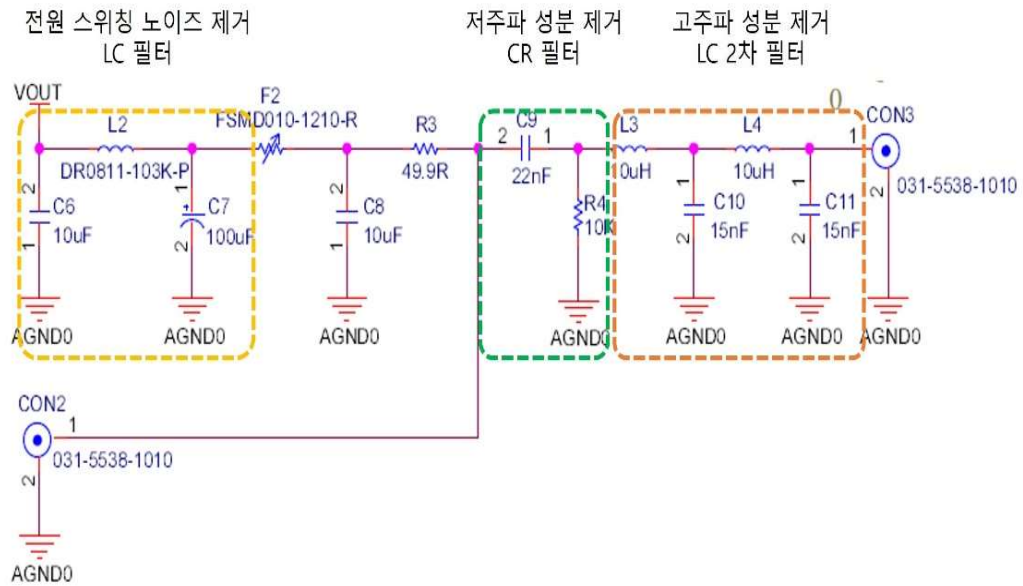
4채널 음향방출 신호와 4채널 진동 가속도 센서 데이터를 실시간으로 데이터 수집이 가능하며, Smart Factory와 같은 생산 설비 내 온·오프라인 네트워크 망 구축이 가능하다.

3.1.1 센서 전원 공급 모듈 설계

대부분의 센서나 시스템에 전원을 공급하기 위해서 스위칭 전원 공급 모듈을 이용한다. 음향방출 센서는 백그라운드 잡음에 매우 취약하다. 양질의 신호를 수집하기 위해서 필터 설계가 필수적이다. 스위칭 전원 공급 모듈을 사용하면 특정 스위칭 노이즈가 발생하는데, 이는 음향방출 신호의 동작 주파수와 같으면 신호 분석에 어려움을 겪을 수 있다. 이번 연구에서 사용한 음향방출 센서의 스펙은 40~100kHz의 동작 주파수와 55kHz의 공진 주파수를 가진다. 음향방출 센서 전원 공급 모듈 내부에 저항, 커패시터, 인덕터와 같이 수동 소자를 활용하여 패시브 필터 밴드 패스 필터를 설계하였다. L-C 저주파 통과 필터를 설계하여 전원 스위칭 노이즈를 저감하였고, C-R 고주파 통과 필터와 L-C 2차 저주파 통과 필터를 통해 400kHz 이상 고주파 성분과 1kHz 이하의 저주파 성분을 제거하였다.



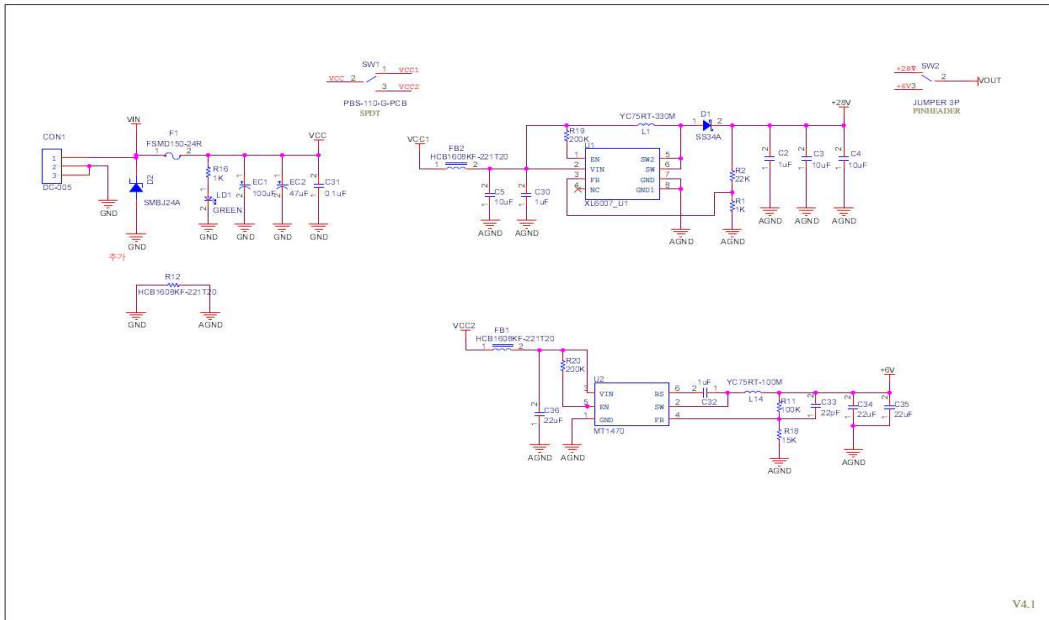
[그림 18] 센서 전원 공급 모듈 구성도



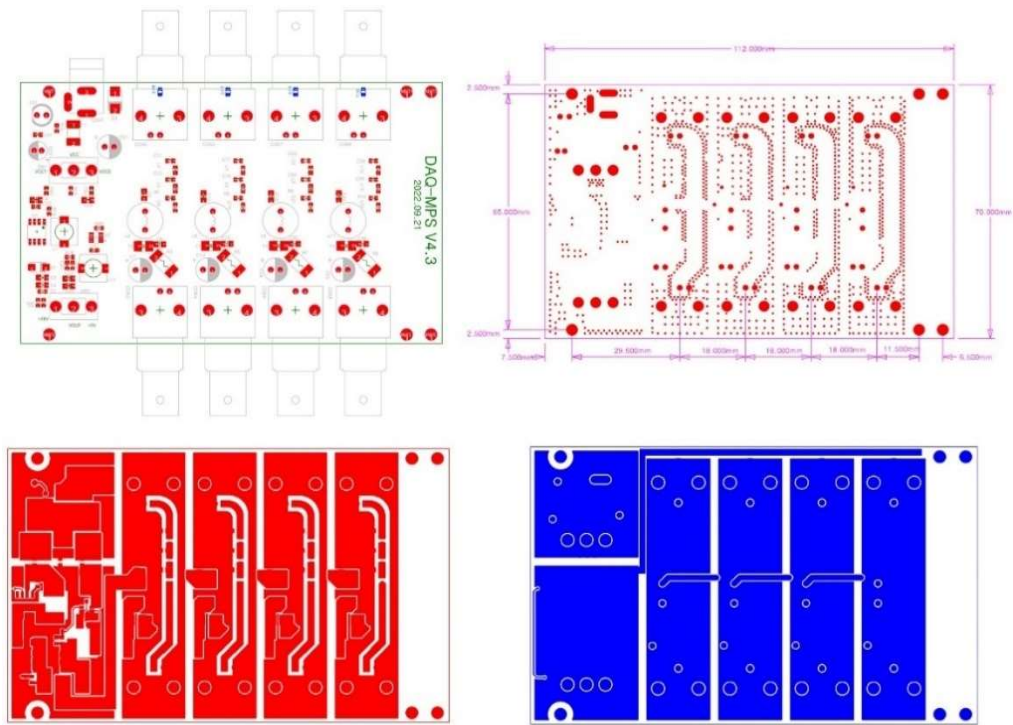
[그림 19] 센서 전원 공급 모듈 필터 회로도

3.1.2 센서 전원 공급 모듈 결과

이번 연구로부터 설계한 전원 공급라인과 필터 라인을 구분하여 회로 설계를 하였고, Artwork 작업을 통해 PCB를 생산하였다. 센서 전원 공급 모듈의 결과물은 아래와 같다.



[그림 20] 스위칭 전원 공급 회로 설계도



[그림 21] 센서 전원 공급 모듈 아트웍 결과

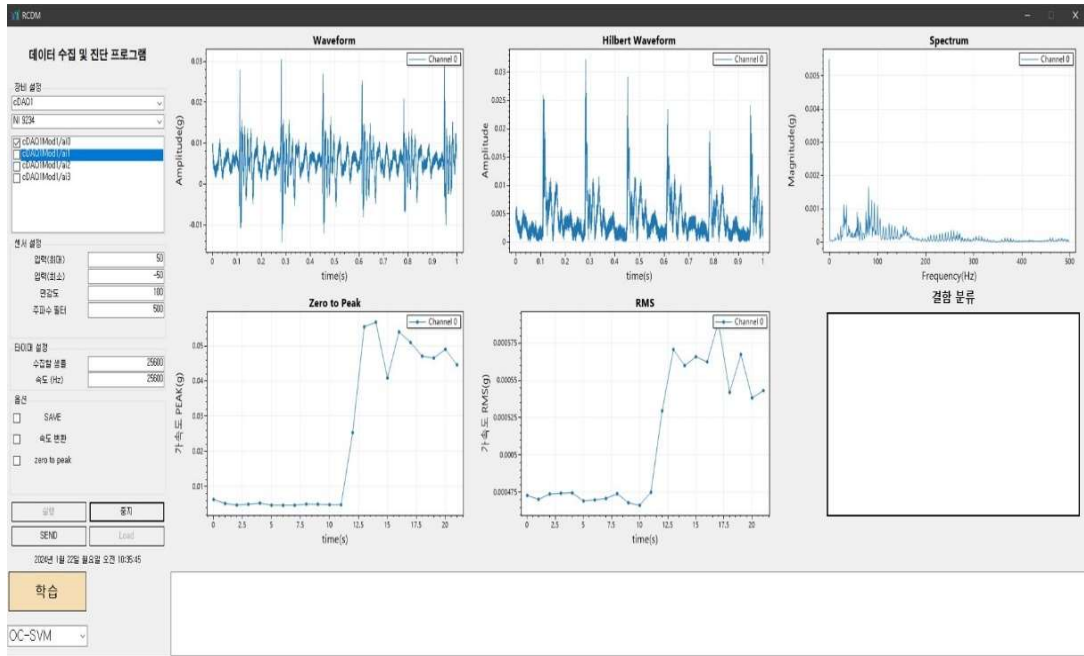


[그림 22] 센서 전원 공급 모듈 최종 결과

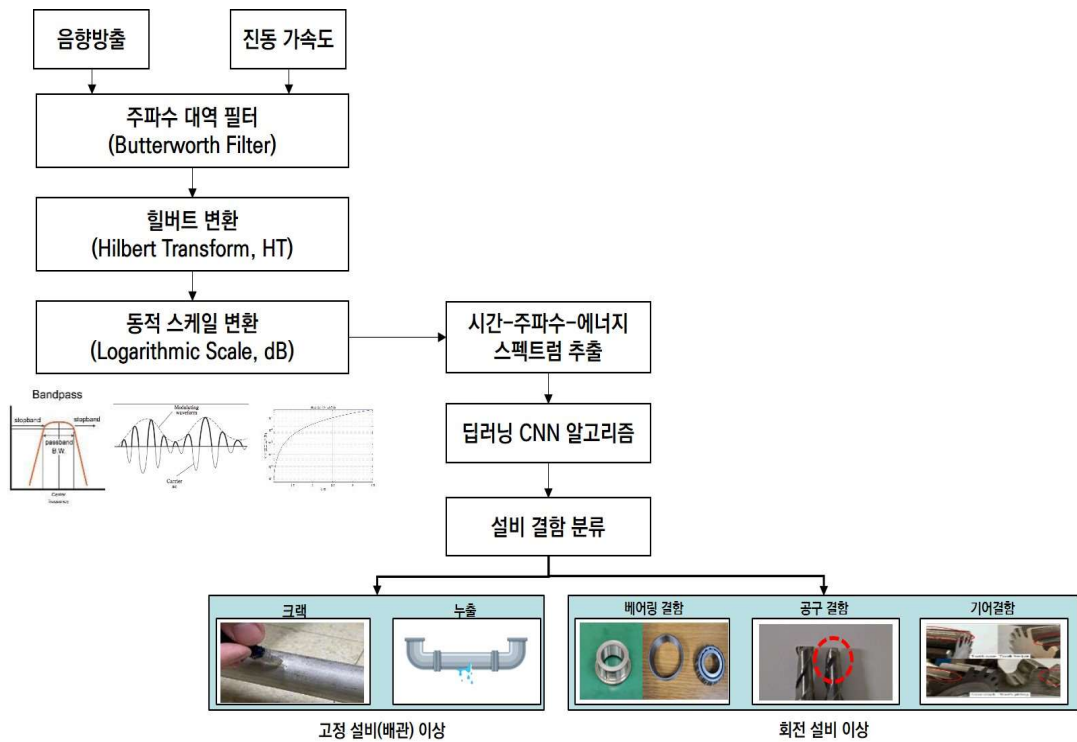
3.2 고장 진단 장치 SW 설계

본 연구에서 개발한 고장 진단 장치의 데이터 수집 프로그램은 NI사의 라이브러리를 기반으로 하여, C# 프로그래밍 언어를 사용하여 개발하였다. 이를 통해, 실시간으로 다중 센

서를 동시에 취득하고 시간 파형의 특징 추출 기능과 주파수 스펙트럼 분석 기능, 딥러닝 모델을 통한 결함 분류 기능이 포함되어 있다.

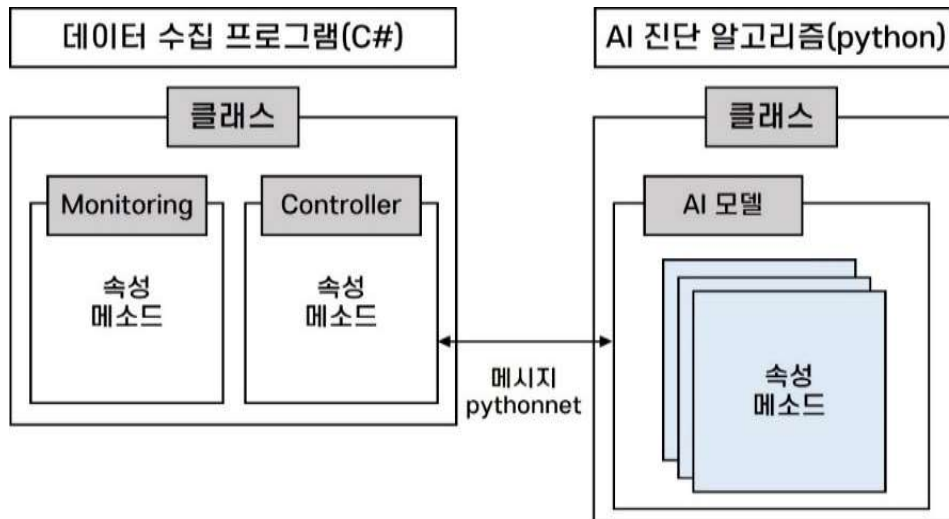


[그림 23] 데이터 수집 프로그램 UI 구성

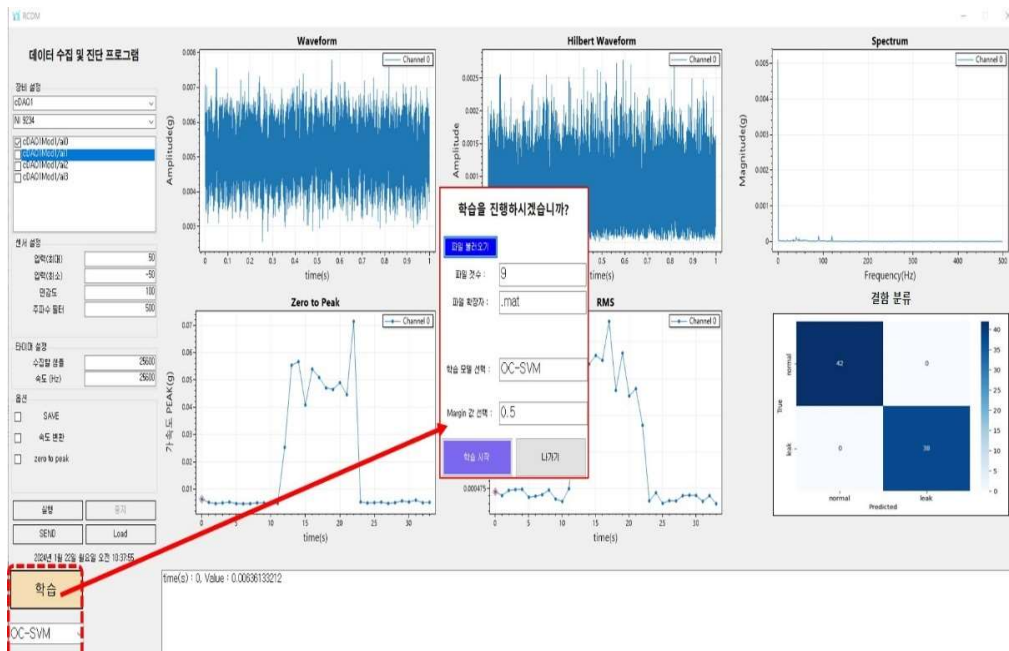


[그림 24] 고장 진단 및 결함 분류 알고리즘 순서도

본 연구에서 개발한 수집 프로그램은 C# 언어를 기반으로 Winform Application으로 구현하였고, 이 프로그램은 사용자 친화적인 인터페이스를 제공한다. 그리고 전처리 알고리즘과 딥러닝 모델은 python 언어로 개발하였고 Scikit-Learn과 PyTorch 패키지를 활용하였다. Pytorch는 심층 학습 모델인 CNN과 같은 인공신경망 구조의 개발하고 학습에 적합한 프레임워크다. C#과 Python을 연동하기 위해 Pythonnet 패키지를 통해 통합하였다. Pythonnet은 C#과 Python간의 상호 운용성을 가능하게 하는 라이브러리이다.



[그림 25] 데이터 수집 프로그램 및 진단 알고리즘 통합 구조



[그림 26] 인공지능 모델 학습

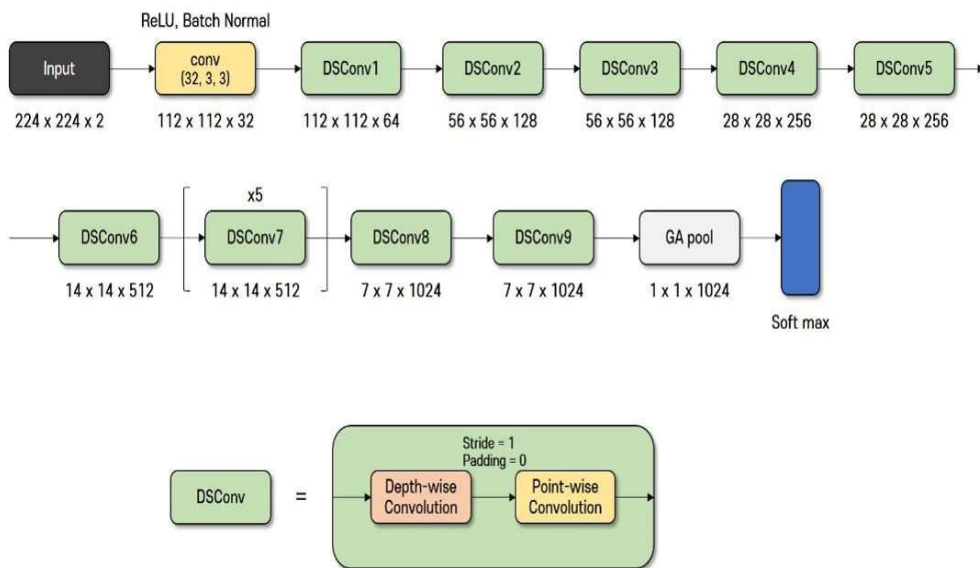
3.3 고장 진단 알고리즘 설계

최근 딥러닝 모델은 기존의 통계적 기법을 포함하여 기존 방법 대비 높은 정확도를 제공함에 따라 많은 응용 분야에서 빠르게 도입, 연구가 되고 있다. 특히, 비전, 자연어 처리, 음성 인식 등의 다양한 분야의 최근 연구들은 딥러닝 모델이 기초가 되고 있다. 더불어, 최근에는 IoT 모바일 기기 및 Edge 디바이스와 같은 저전력, 저성능의 제약을 가지는 장치에서도 동작할 수 있도록 딥러닝 모델을 최소화하는 연구들이 많이 진행되고 있다[18].

본 연구의 설비 고장 진단 알고리즘은 음향방출 및 진동 가속도 센서로부터 데이터를 수집하고, 주파수 필터, 힐버트 변환, 스케일 변환, 연속 웨이블릿 변환 등 전처리 알고리즘을 통해 데이터를 가공한 후, 딥러닝 CNN 네트워크 모델을 통해 학습한다. 그리고 각 설비의 주요 결함들을 분류한다. 해당 본문에서는 딥러닝 기반 고장 진단 방법에 대해 기술한다.


3.3.1 딥러닝 기반 고장 진단 결함 분류 모델

Convolutional Neural Network(CNN, 합성곱 신경망)은 딥러닝 신경망 모델 중 한 유형으로, 이미지 분류, 객체 탐지, 얼굴 인식 등 다양한 분야에서 활용된다. 이미지로부터 공간적, 지역적 정보를 훼손하지 않고 유지하며 특징을 추출해야 효율적인 이미지 처리가 가능하다. 진동이나 소리, 초음파와 같은 신호를 분석하기 위해서는 스펙트로그램, 웨이블릿 변환, 힐버트-황 변환 등과 같은 3차원 이미지 분석이 필요하다. 그리고 모바일 기기 및 Edge 디바이스와 같은 저 사양의 메모리 환경에서 딥러닝 모델을 적용하기 위해서는 경량화된 모델이 필요하며, 2017년에 구글에서 개발한 네트워크 구조인 MobileNet이 적절한 모델이 될 것으로 판단하였다[19]. MobileNet 네트워크 구조는 일반적인 CNN 모델에 비해 매개변수와 계산량이 크게 감소된 모델이다. 이번 연구에서 사용한 MobileNet의 네트워크 구조는 다음 그림과 같다.




[그림 27] MobileNet 딥러닝 네트워크 모델 구조

MobileNet은 Depth-wise Separable Convolution 구조를 사용하여 일반적인 CNN 구조에 비해 매개변수와 계산량을 대폭 줄였다. Depth-wise Separable Convolution은 Depth-wise Convolution과 Point-wise Convolution을 결합한 형태의 네트워크 구조이다.



[그림 28] Depth-wise Separable Convolution 네트워크 구조

일반적인 CNN 모델은 입력 데이터가 3채널이면, Convolution 연산의 필터 크기도 3채널이어야 한다. MobileNet 네트워크 구조는 입력 데이터에 Convolution 연산을 수행할 때 모든 채널을 한번에 계산해서 출력해야 하는가에 대한 의문점에서 시작되었다.



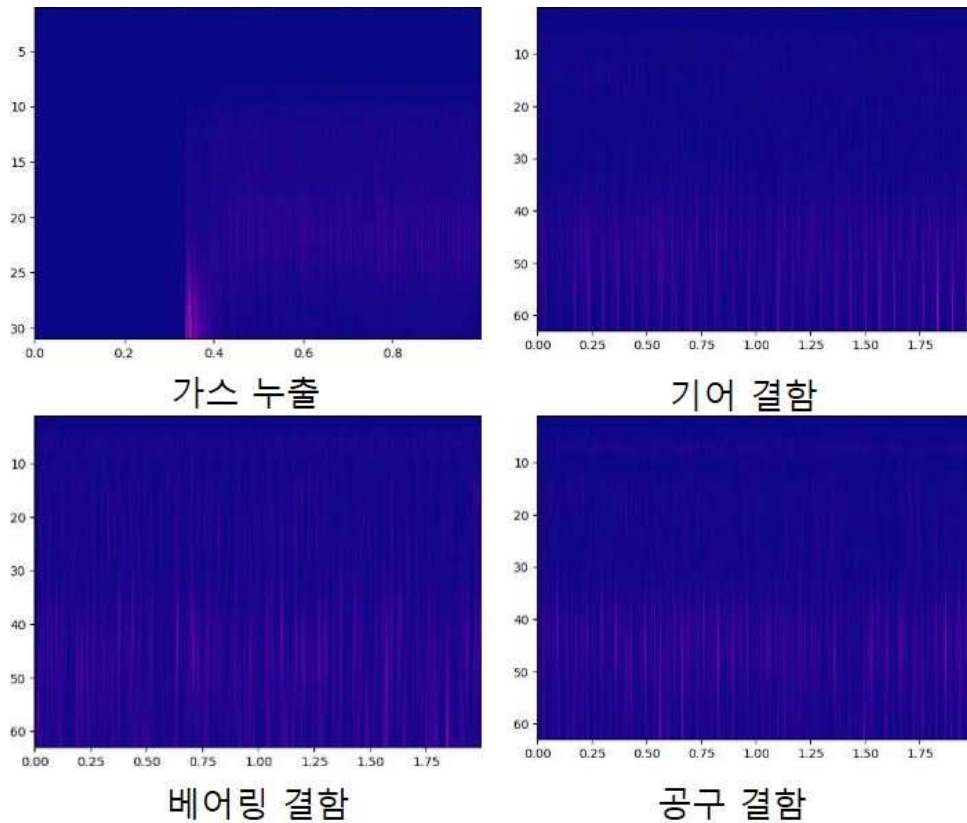
[그림 29] 일반적인 CNN Convolution 연산과의 비교[16]

이러한 분리 연산을 통해 MobileNet은 일반적으로 사용되는 Convolution 연산보다 훨씬 적은 파라미터와 연산으로 동일한 작업을 수행할 수 있다. 구글에서 제시한 MobileNet 네트워크 구조는 아래 표 1과 같다.

Type/Stride	Filter Shape	Input Size
Conv / s2	3 x 3 x 3 x 32	224 x 224 x 3
Conv dw / s1	3 x 3 x 32 dw	112 x 112 x 32
Conv / s1	1 x 1 x 32 x 64	112 x 112 x 32
Conv dw / s2	3 x 3 x 64 dw	112 x 112 x 64
Conv / s1	1 x 1 x 64 x 128	56 x 56 x 64
Conv dw / s1	3 x 3 x 128 dw	56 x 56 x 128
Conv / s1	1 x 1 x 128 x 128	56 x 56 x 128
Conv dw / s2	3 x 3 x 128 dw	56 x 56 x 128
Conv / s1	1 x 1 x 128 x 256	28 x 28 x 128
Conv dw / s1	3 x 3 x 256 dw	28 x 28 x 256
Conv / s1	1 x 1 x 256 x 256	28 x 28 x 256
Conv dw / s2	3 x 3 x 256 dw	28 x 28 x 256
Conv / s1	1 x 1 x 256 x 512	14 x 14 x 256
5 x Conv dw / s1	3 x 3 x 512 dw	14 x 14 x 512
Conv / s1	1 x 1x 512 x 512	14 x 14 x 512
Conv dw / s2	3 x 3 x 512 dw	14 x 14 x 512
Conv / s1	1 x 1 x 512 x 1024	7 x 7 x 512
Conv dw / s2	3 x 3x 1024 dw	7 x 7 x 1024
Conv / s1	1 x 1x 1024 x 1024	7 x 7 x 1024
Avg Pool / s1	Pool 7 x 7	7 x 7 x 1024
FC / s1	1024 x 1000	1 x 1 x 1024
Softmax / s1	Classifier	1 x 1 x 1000

[표 2] MobileNet 네트워크 모델의 기본 구조

이번 연구에서 CNN 모델의 입력 데이터로 사용된 데이터는 센서 데이터를 3차원 시간-주파수-에너지 스펙트럼 이미지이다.



[그림 30] CNN 모델의 입력 데이터 형태

3.3.2 딥러닝 분류 모델 성능 평가 방법

최종적으로 딥러닝 모델의 성능을 평가하기 위하여 Confusion Matrix를 사용하였다. 이 방법은 실제 클래스와 모델이 예측한 클래스의 관계를 나타내며, 모델이 어떤 클래스를 잘 예측하는지 또는 혼동하는지 쉽게 파악할 수 있는 방법이다. Confusion Matrix는 일반적으로 다음과 같이 행렬 형태로 구성된다.

	예측 Positive	예측 Negative
실제 Positive	True Position (TP)	False Negative (FN)
실제 Negative	False Positive (FP)	True Negative (TN)

[표 3] Confusion Matrix 4가지 Condition

Confusion Matrix 구조에서 TP는 실제로 Positive인 데이터를 모델이 Positive로 정확하게 예측한 경우, FP는 실제로 Negative인 데이터를 모델이 Positive로 잘못 예측한 경우, TN은 Negative인 데이터를 모델이 Negative로 정확하게 예측한 경우, FN은 Positive인

데이터를 모델이 Negative로 잘못 예측한 경우이다. 추가로, Confusion Matrix를 통해 알 수 있는 대표적인 성능 지표는 다음과 같다.

구분	수식	설명
특이도 (Specificity)	$\frac{TN}{FP + TN}$	N 레이블인 항목 중에서 N 레이블로 옳게 예측된 항목의 비율
민감도, 재현율 (Sensitivity, Recall)	$\frac{TP}{FN + TP}$	P 레이블인 항목 중에서 P 레이블로 옳게 예측된 항목의 비율
정밀도 (Precision)	$\frac{TP}{FP + TP}$	레이블로 예측된 항목중에서 P 레이블로 옳게 예측된 항목의 비율
정확도 (Accuracy)	$\frac{TP + TN}{TP + TN + FP + FN}$	얼마나 정확하게 분류해냈는지 평가하는 척도
F1 Score	$2 \times \frac{\text{정밀도} \times \text{재현율}}{\text{정밀도} + \text{재현율}}$	정밀도와 재현율의 조화 평균

[표 4] Confusion Matrix를 이용한 대표적인 성능지표

4. 고장 진단 시스템 성능 검증


제안된 산업 설비 고장 진단 장치를 결함 모사 테스트베드에 적용하였다. 이를 위해 각 설비에서 발생하는 주요 결함을 조사하여 결함 데이터를 수집하였다. 학습된 CNN 딥러닝 네트워크 모델을 통해 설비의 상태를 진단하였고, 평가 결과를 통해 실제 현장에 적용이 가능한지 검토하였다.

4.1 지하배관 결함 모사 테스트베드 검증

지하 배관에서는 주로 부식, 크랙, 누출로 인해 배관이 손상된다. 이러한 결함의 특징들은 재료의 미소 균열이나 진동의 생성, 성장하게 되는데, 결함의 발생 징후를 사전에 검증하기 위해서는 음향방출 검사를 통해 신호를 분석할 수 있다. 결함이 발생하는 시점부터 불연속 신호나, 진행 중에 있는 동적인 신호를 분석하기에는 음향방출 센서가 적합할 것으로 판단하였고, 타 공사에 의해 발생하는 배관 파손 문제는 파손되기 전에 큰 충격 신호가 지속적으로 발생할 것으로 파악되며, 가속도 진동 센서가 타 공사와 같은 큰 충격 신호를 검출할 수 있다. 위와 같은 결함들을 분류하고 진단에 활용된 데이터는 산업용 지하배관을 모사한 테스트베드를 통해 결함별로 데이터를 취득하였다. 센서의 설치 위치와 정보는 그림 30과 같다.



[그림 31] 산업용 지하배관 결함모사 테스트베드



[그림 32] 산업용 지하배관 결함모사 테스트베드 도면

No	매개변수	치수/정보
1	센서 1 위치	0 mm
2	센서 2 위치	2,000mm
3	누수 위치	300/800/1,500 mm
4	배관 두께/직경	3.65mm / 50A
5	배관 재질	Carbon steel
6	물질	공기
7	데이터 수집율	1 MHz

[표 5] 실험에 사용된 테스트베드 정보

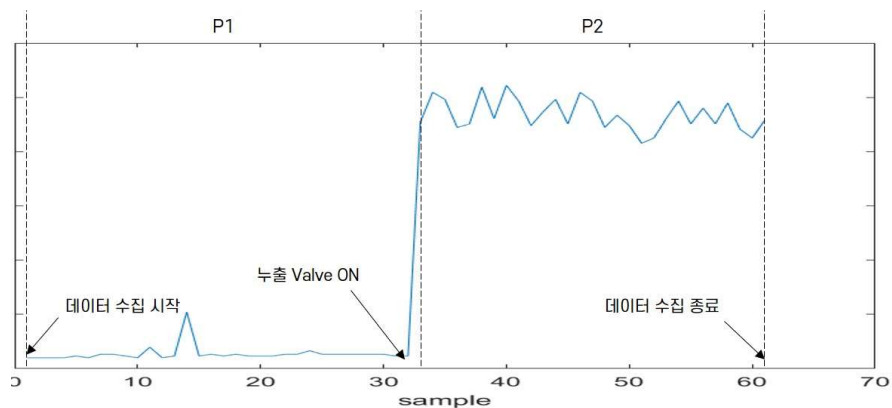
데이터 수집 절차는 그림 31과 같이 진행하였고, 데이터 수집과 진단은 4단계 과정으로 이루어진다.

- 1단계: 탄성과 및 진동 신호를 센서를 통해 아날로그 신호로 변환
- 2단계: 아날로그 신호를 데이터 수집 및 진단 장치를 통해 디지털 신호로 변환
- 3단계: TCP/IP 내부 이더넷 통신을 통해 데이터를 저장
- 4단계: 고장 진단 소프트웨어를 통해 데이터 분석 및 진단을 수행



[그림 33] 데이터 수집 및 진단 절차 순서

지하배관의 상태 데이터를 취득하기 위해 MISTRAS社에서 제조 생산된 R6I-AST 음향 방출 센서를 사용하였고, 진동 가속도 센서는 VibraSens社에서 생산되는 101.51 고감도 IEPE 타입 가속도 센서를 사용하였다. 음향방출 센서와 진동 센서는 표 5에 명시된 매개변수에 따라 해당하는 위치 웨이브가이드를 이용해 설치하였고, 배관 내부 압력 3.8~4.2bar의 환경에서 수행하였고, 정상, 크랙, 누출 상태에 대해 1분 동안 수집하였다.




[그림 34] 테스트베드 데이터 수집 절차

No	매개변수	값
1	BPF	40 - 100 kHz
2	Wavelet 함수	Mexican hat
3	Wavelet Scale	32


[표 6] 지하배관 결함모사 테스트베드 전처리 파라미터

수집된 데이터를 전처리 과정과 웨이블릿 변환을 통해 3채널 이미지로 추출하고, 추출된 시간-주파수-에너지 스펙트럼을 224x224 크기의 Gray scale로 변환하여 CNN 딥러닝 모델에 입력하였다. 지하배관 결함모사 테스트베드의 결함 분류 결과는 그림 33과 같이 Confusion matrix로 표현하였고, 모델을 학습한 결과 정상, 크랙, 누출에 대해 96.95% 정확도를 보였다.



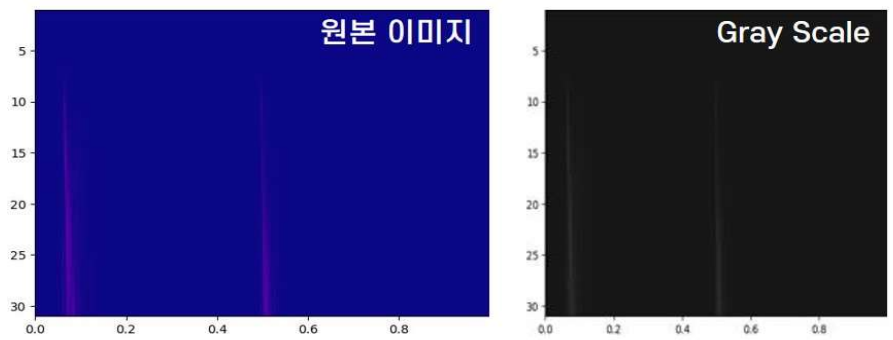
[그림 35] 지하배관 테스트베드 딥러닝 모델 학습 Confusion matrix 결과

1. 정상




모델 예측 정확도 : leak: 0.26%, **normal: 99.35%**, crack: 0.39%

2. 크랙

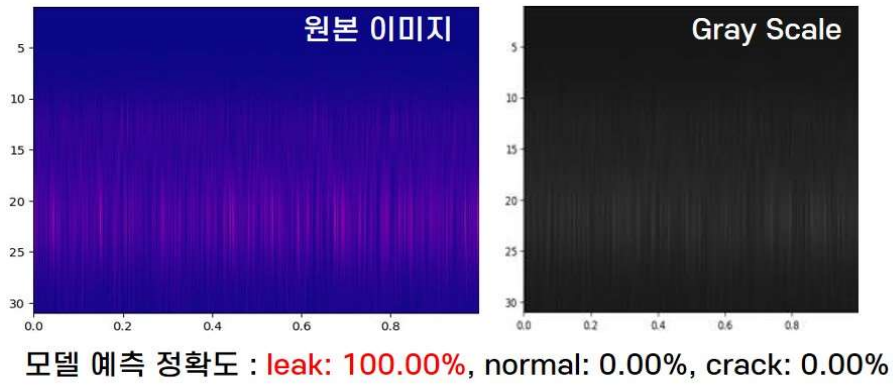


모델 예측 정확도 : leak: 0.08%, **normal: 1.29%**, **crack: 98.63%**

3. 누출 1




4. 누출 2




[그림 36] 지하배관 테스트베드 상태 분류 및 모델 성능 검증

4.2 화학 교반기 결함 모사 테스트베드 검증



[그림 37] 산업용 화학 교반기 기본 구조

일반적인 화학 교반기는 화학 실험 및 제조 화학에서 기체, 액체, 고체의 물체를 섞어주는 장비를 말한다. 화학 산업 분야에서 중요한 역할을 담당하는 장비이다. 교반기는 지속적인 가동으로 인해 피로 누적, 변형, 노후화가 진행되는 것이 일반적이며 올바른 관리를 하지 않을 경우, 생산성 저하, 품질 및 경제적 손실이 발생할 수 있다. 그림 35는 교반기의 주요 구조를 나타내었다. 주요 구성은 모터, 기어박스, 베어링, 구동축 그리고 축에 설치된 임펠러이다. 교반기에서 발생할 수 있는 주요 결함은 큰 하중을 견디는 구동축의 기어 결함, 축의 하중을 지지하는 베어링 결함, 화학 반응 및 침전물 형성으로 인한 임펠러 결함이 주로 발생 되는 결함이다. 산업용 교반기의 결함을 모사한 테스트베드는 그림 36과 같이 구축하였다.



[그림 38] 산업용 화학 교반기 결함모사 테스트베드

교반기와 같은 회전 기계는 진동 가속도 센서를 통해 결함을 진단하는 방법은 널리 사용되는 방법이다. 회전 기계의 특성상 결함 신호들이 운전 주파수와 관계있는 주파수 대역에서 발생하기 때문에, 진동 가속도 센서를 선정하였다. 교반기 결함모사 테스트베드의 기어 박스는 그림 37과 같이 3축으로 구성되어 있으며, 2단 감속이 이루어진다. 1차 감속 비는 2/3, 3차 감속 비는 11/24, 총 감속 비는 11/36이다. 가속도 진동 센서를 모터 직교 방향으로 채널 1, 2에 설치하고, 구동 축 방향으로 채널 3, 구동 축 베어링과의 최단 거리에 채널 4를 설치하였다. 테스트베드의 기본 정보는 표 6와 같다.



[그림 39] 기어 박스 내부 구조 및 센서 설치 위치

No	매개변수	주파수 대역
1	모터 RPM	30 Hz
2	감속 축 RPM	20 Hz
3	1차 GMF	960 Hz
4	2차 GMF	440 Hz
5	베어링 외륜 결함 주파수	6.16 Hz
6	베어링 내륜 결함 주파수	8.84 Hz


[표 7] 교반기 결함모사 테스트베드 기본 정보

베어링, 기어, 임펠러 등 주요 결함의 데이터를 600개씩 취득하였고, 수집된 데이터를 연속 웨이블릿 변환을 통해 시간-주파수-에너지 스펙트럼을 추출하였다. 전처리 과정에서 사용된 파라미터는 표 7과 같다.

No	매개변수	값
1	BPF	0.4 - 1.6 kHz
2	Wavelet 함수	Morlet
3	Wavelet Scale	64

[표 8] 교반기 결함모사 테스트베드 전처리 파라미터


수집된 데이터를 전처리 과정과 웨이블릿 변환을 통해 3채널 이미지로 추출하고, 추출된 시간-주파수-에너지 스펙트럼을 224x224 크기의 Gray scale로 변환하여 CNN 딥러닝 모델에 입력하였다. 산업용 교반기 결함모사 테스트베드의 결함 분류 결과는 그림 38과 같이 Confusion matrix로 표현하였고, 모델을 학습한 결과 정상, 베어링, 기어, 임펠러에 대해 94.40% 정확도를 보였다.



[그림 40] 교반기 테스트베드 딥러닝 모델 학습 Confusion matrix 결과


위와 같이 실험을 통해 베어링, 기어, 임펠러 결함, 정상상태에 대해 모델을 검증한 결과는 다음과 같이 예측되었다.

1. 정상 상태




모델 예측 정확도 : Inner: 0.00%, Gear: 0.00%, Outer: 0.00 %,
Impeller: 0.00 %, **Normal: 100.00%**

2. 베어링 Inner 결함



모델 예측 정확도 : **Inner: 98.82%**, Gear: 0.00%, Outer: 0.68%
Impeller: 0.49%, Normal: 0.01%


3. 기어 결함



모델 예측 정확도 : Inner: 0.00%, **Gear: 100.00%**, Outer: 0.00 %
Impeller: 0.00 %, Normal: 0.00%

[그림 41] 교반기 테스트베드 상태 분류 및 모델 성능 검증

4.3 머시닝센터 결함 모사 테스트베드 검증




[그림 42] 공작기계 결함모사 테스트베드

공작기계는 주로 금속 공작물을 절삭, 연삭 등에 의하여 불필요한 부분을 제거하여 형상을 만드는 기계이다. 특히, 대표적인 공작기계 중 하나인 머시닝센터는 자동으로 공구를 바꾸어 가며 형상을 만들어 내는 장비이다. 머시닝센터에 결함이 발생할 경우, 품질, 생산성에 큰 영향을 미칠 수 있다. 머시닝센터의 주요 결함은 그림 40에서 보이는 것처럼 베어링 결함, 기어 결함, 절삭공구 결함 등이 있다. 베어링 결함은 질량 불평형, 축 정렬 불량 등 베어링에 과도한 부하가 작용할 경우, 외륜, 내륜 등 구성품에 크랙 및 마모가 발생할 수 있으며, 결함이 심할 경우 과도한 진동과 소음이 발생할 수 있다. 그리고 기어 결함은 부적절한 윤활이나, 과도한 하중이 가해지면 마모, 크랙, 파손 등의 결함이 발생할 수 있으며, 기어의 마모는 전력 전달 효율을 감소시키며, 진동과 소음을 발생시킬 수 있다. 머시닝센터에서 공구 결함이 발생하면 다른 결함과 마찬가지로 제품의 품질과 생산성에 문제가 발생한다. 공구의 마모나 파손으로 인해 가공 표면의 거칠기나 치수의 오차가 발생하고 공구의 수명이 단축되며, 공구가 예기치 않게 파손된다면 생산이 중단되어 비 계획적인 다운이 발생할 수 있기 때문에, 베어링, 기어, 공구의 조기 결함을 찾는 것이 중요하다. 조기 결함 탐지에 적절한 음향방출 센서와 회전 설비를 진단하기에 적절한 진동 가속도 센서를 사용하여 결함을 분류하고 진단하였다.

No	매개변수	값
1	BPF (AE, Vib)	40 - 100 kHz, 0.4 - 1.6 kHz
2	Wavelet 함수 (AE, Vib)	Mexican hat, Morlet
3	Wavelet Scale (AE, Vib)	32, 64

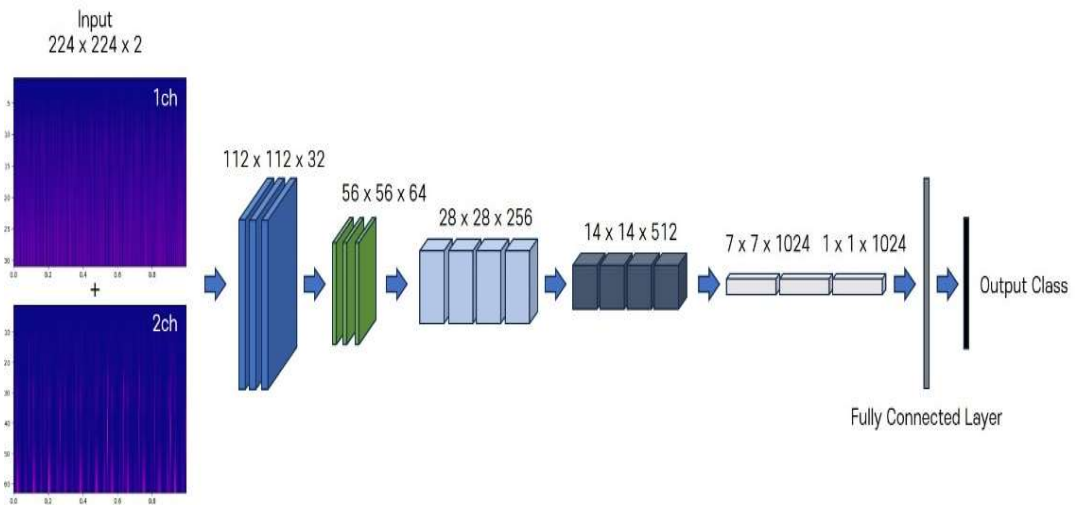
[표 9] 머시닝센터 결함모사 테스트베드 전처리 파라미터

모터 회전속도 1,320 RPM, 스피들 회전속도 660 RPM 환경에서 결함별로 2초 신호를 15회 반복하였다. 센서 설치 위치는 머시닝센터 Chuck지지 베어링 하우징에 500mV/g 감도의 진동 가속도 센서와, 55kHz 공진 주파수를 가지는 음향방출 센서를 설치하였다. 공작 기계의 특성상 대상체를 가공할 때 나타나는 노이즈에 결함 특징 신호들이 묻혀 결함 구분이 쉽지 않았다. 진동 가속도 센서로만 분류하면 38.33%로 학습 정확도가 매우 낮았다.




[그림 43] 머시닝센터 테스트베드 Confusion matrix 결과 1

진동 가속도 센서와 음향방출 센서를 동시에 데이터를 수집하고, 음향방출 센서의 시간-주파수-에너지 스펙트럼을 1채널로, 진동 가속도 센서의 시간-주파수-에너지 스펙트럼을 2채널로 구성된 데이터를 CNN 모델의 입력으로 한다. 센서의 신호를 결합한 다중 채널 기반 CNN 모델의 구조는 다음과 같이 구성하였다.



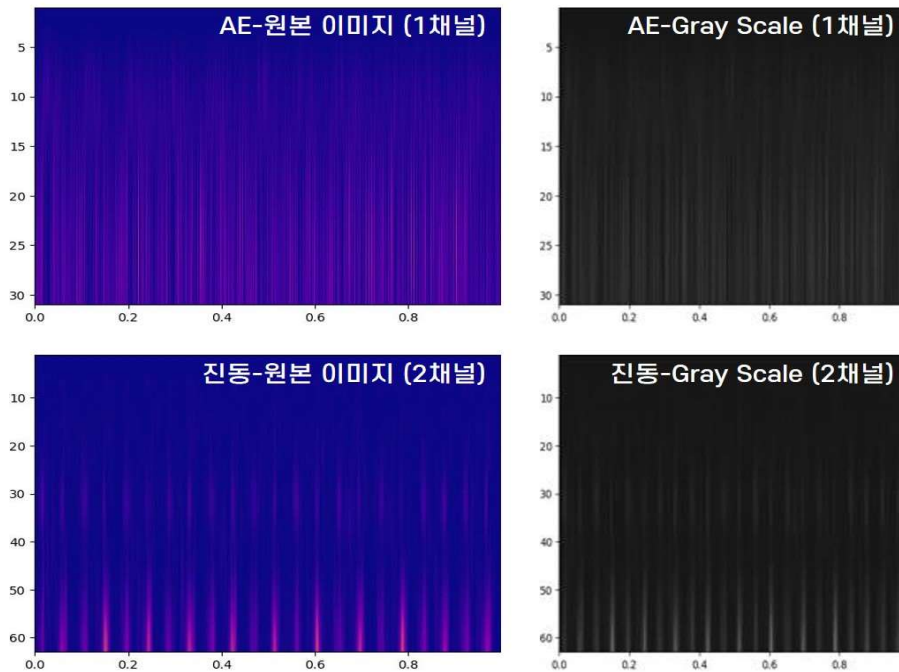
[그림 44] 다중 채널 기반 CNN 모델 구성도

그림 47과 같이 정상과 주요 결함들을 잘 분류하였고, 학습 정확도는 98.33%로 나타났고, 새로운 데이터에 대한 모델 예측 정확도는 그림 44와 같이 출력되었다.




[그림 45] 머시닝센터 테스트베드 Confusion matrix 결과 2

1. 정상




모델 예측 정확도 : 베어링 결함: 2.09%, 기어 결함: 6.50%,
정상: 87.32%, 공구 결함: 4.09%

2. 베어링 결함




모델 예측 정확도 : **베어링 결함: 99.54%**, 기어 결함: 0.15%,
 정상: 0.14%, 공구 결함: 0.18%

3. 기어 결함



모델 예측 정확도 : 베어링 결함: 0.24%, **기어 결함: 99.61%**,
 정상: 0.03%, 공구 결함: 0.12%

4. 공구 결함



모델 예측 정확도 : 베어링 결함: 1.61%, 기어 결함: 0.14%,
 정상: 0.43%, **공구 결함: 97.82%**

[그림 46] 머시닝센터 테스트베드 상태 분류 및 모델 성능 검증

5. 결론

본 연구에서는 노후화된 산업 설비에서 발생하는 여러 가지 문제점들을 해결하고 설비의 상태를 진단하기 위해 음향방출 센서와 진동 가속도 센서를 결합한 다중 센서 기반의 고장 진단 장치를 개발하고, 전처리 알고리즘과 딥러닝 모델을 탑재하여 산업 설비의 상태를 진단하고 결함을 분류하는 것이 목표이다. 원신호로부터 각 센서의 특성에 맞도록 필터를 설정하여 불필요한 주파수 대역을 제거하고, 힐버트 변환을 통해 포락선을 추출하여 신호의 에너지 분포와 변동 패턴이나 베어링, 기어가 결함을 만날 때, 발생하는 충격성 주파수를 추출하였다. 그리고, 연속 웨이블릿 변환을 통해 시간-주파수-에너지 스펙트럼을 추출하여 딥러닝 기반 CNN 모델의 입력 데이터로 사용하였다. 산업 현장과 같은 노이즈가 많이 혼합된 환경에서는 신호들을 분류하기 어렵기 때문에, 주파수 필터, 힐버트 변환, 연속 웨이블릿 변환과 같은 전처리 과정을 거쳐야만 의미 있는 신호들이 추출되었다.

본 연구에서 고장 진단 장치와 딥러닝 모델을 검증하기 위해 3 가지의 결함모사 테스트베드를 통해 검증하였다. 각 테스트베드의 CNN 모델 검증 정확도는 지하배관 결함 모사 테스트베드는 96.95%, 산업용 교반기 결함 모사 테스트베드는 94.40%, 머시닝센터 결함 모사 테스트베드는 98.33%로 수렴하였다. 학습된 모델을 고장 진단 장치에 데이터 수집 프로그램과 함께 탑재하여 결함 모사 테스트베드에서 상태를 분류한 결과 각 결함 들에 대해 잘 분류할 수 있었고, 준수한 성능을 보여주었다. 본 연구를 통해 제안한 고장 진단 장치는 환경에 제약없이 모든 설비들에 검증할 수 있을 것이라 판단하였고, 각 산업 설비마다 딥러닝 모델을 생성한다면 모든 설비들에 대해 상태를 진단할 수 있을 것으로 판단된다. 또한, 기존의 비파괴 검사나 상태기반정비의 경우에 전문가의 경험이 필요한데, 전문가의 경험이나 지식이 고장 진단 장치에 녹여 일반 사용자들도 최소한의 파라미터 설정으로 설비의 상태를 진단할 수 있도록 개발을 하였다. 전처리 알고리즘과 딥러닝 네트워크 모델을 및 고장 진단 장치를 지속적으로 고도화시켜 산업현장의 많은 설비들의 안전성과 지속성을 높이고, 생산 설비의 운용에 있어 효율을 증가시킬 수 있는 중요한 역할을 할 것으로 판단된다.

향후 연구 방향으로는 실제 산업 현장에 실증하여 범용성을 높이고, 이를 통해 다양한 환경과 노후화된 설비의 위험성과 생산 효율을 증가시킬 것으로 기대된다. 그리고 전이 학습 및 설명가능한 인공지능 등을 포함한 고도화된 알고리즘들을 추가하여 새로운 모델, 환경에 적용시키고자 한다.

참고 문헌

- [1] Hyong-Shik. Chun(1994), “예방(예지) 정비의 필요성”, 한국소음진동공학회지, vol. 4, no. 4, pp. 459-467
- [2] GOLASKI. L(2002), “Diagnostics of Reinforced Concrete Bridges By Acoustic Emission”, J. Acoustic Emission, 20, pp.83-98.
- [3] R. Unnorsson, “Hit Detection and Determination in AE Burst”, in Acoustic Emission - Research and Application, 2013, ch. Chapter 1.
- [4] 정인규(2021), “배관 상태 진단을 위한 음향방출 신호처리 기술 연구”, 울산대학교, 공학박사학위논문
- [5] 김원일(2013), “음향방출 신호에 의한 공작기계 기어상자와 축의 상태감시 및 진단에 관한 연구”, 경남대학교, 공학박사학위논문
- [6] Ferrando Chacon, J. L.(2015), “Fault Detection in Rotating Machinery Using Acoustic Emission”, Brunel University London, Doctoral Thesis..
- [7] 정정호, 김정욱, 2008, “진동 측정을 통한 설비 진단”, Fire protection technology, no. 44, pp. 30-43.
- [8] Reliability Direct, “ISO 10816 Vibration Severity Chart”, 2013.
- [9] Moubray, J. (1997), “Reliability-Centered Maintenance II”, Industrial Press.
- [10] Hebrard, Y., 2019, “Combination of vibration analysis and Acoustic Emission measurement to better characterize damage and mechanical behaviour of aerospace high speed rolling bearing”, 33RD European Conference on Acoustic Emission Testing.
- [11] Abdullah M. Al-Ghamdi, D.Zhechkov and D. Mba, 2004, “The use of Acoustic Emission for bearing defect identification and estimation of defect size”, 26th European Conference on Acoustic Emission Testing.
- [12] Carcaterram A., & Sestieri, A., 1997, “Complex envelope displacement analysis: A quasi-static approach to vibrations”, Journal of Sound and Vibration, no. 201, pp. 205-233.
- [13] M. Feldman, 2011, “Hilbert transform in vibration analysis”, Mechanical Systems and Signal Processing, vol. 25, pp. 735-802.
- [14] Byung-Hyun A., 2014, “Signal Processing Technology for Rotating Machinery Fault Signal Diagnosis”, Trans. Korean Soc. Noise Vib. Eng., Vol. 24, no. 7, pp.555-561.
- [15] DongSik. Gu(2011)., “Detection of faults in gearboxes using acoustic emission signal”, Journal of Mechanical Science and Technology, vol. 25, pp.1279-1286.
- [16] DongSik. Gu.(2008), “Application of Envelop Analysis and Wavelet Transform for Detection of Gear Failure”, KSME, vol. 32, no. 11, pp. 905-910.
- [17] Smith, L. C., Turcotte, D. L., and Isacks, B. L., 1988, “Stream flow characterization and feature detection using a discrete wavelet transform.”, Hydrological processes, vol. 12, no. 2, pp. 233-249.
- [18] Misiti, M., Misiti, Y., Oppenheim, G., and Poggi, J. M., 2013, “Wavelets and their Applications”, John Wiley & Sons, New York, N.Y.

- [19] Jinwook, L., 2019, “Selection of mother wavelet for bivariate wavelet analysis”, Journal of Korea Water Resources Association, pp. 905–916.
- [20] 이경하, 김은희, 2020, “딥러닝 모델 경량화 기술 분석”, 한국과학기술정보연구원.
- [21] AG. Howard, 2017, “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications”.

[Abstract]

A Study on Fault Diagnosis of Industrial Equipment Using Multi-Sensor Based Wavelet Transform and CNN Deep Learning Model

In the petrochemical industry, essential equipment such as piping, tanks, agitators, and compressors are crucial components of modern industrial facilities. Frequent defects in both fixed and rotating equipment include corrosion, cracks, leaks, wear, and fatigue failure. These defects can lead to productivity loss and accidents due to aging, necessitating early defect analysis to prevent such incidents. However, inspecting equipment conditions and diagnosing defects in industrial settings require specialized knowledge and experience, making early defect detection and condition diagnosis impossible without experts. Tools are needed for maintaining the stability and reliability of rotating equipment in smart factories that operate condition-based maintenance without on-site experts. Automatically diagnosing conditions and classifying defect causes by collecting signals from industrial equipment would greatly aid maintenance.

According to the P-F curve, ultrasonic signals are generated at the initial stage of defect occurrence, and as the defect progresses, changes in vibration occur. To analyze ultrasonic and vibration signals, this study proposes the development of a multi-sensor-based fault diagnosis device. The system includes preprocessing algorithms and a deep learning network model to classify defects. The proposed preprocessing algorithms include Butterworth band-pass filter, Hilbert transform, log-scale transformation, and continuous wavelet transform, ultimately producing a time-frequency-energy spectrum. First, the Butterworth band-pass filter removes unnecessary high and low-frequency components of the signal, allowing only the desired frequency band to pass through, based on the operating frequency range provided by the sensor manufacturer. The Hilbert transform is used to extract the instantaneous amplitude and phase information of the signal by utilizing the real and imaginary parts. Envelope extraction through this method detects subtle impact signals caused by pipeline leaks, gear defects, and bearing defects. Lastly, the continuous wavelet transform analyzes the frequency components of the signal over time at various scales to extract specific patterns from the signal. The 2-D spectrum image generated through these preprocessing steps is used as input to a lightweight network model, MobileNet CNN. To validate the developed device and algorithms, performance was tested in three different environments simulating underground pipeline defects, industrial agitator defects, and machining center defects. The fault diagnosis device developed in this study is expected to facilitate

equipment condition diagnosis without requiring specialized knowledge, thereby preventing accidents due to aging, productivity loss, and cost loss.

This proposed fault diagnosis system with multi-sensor signal measurement and automatic defect classification aims to contribute to safer and more efficient maintenance practices in industrial facilities.

keyword : Fault Diagnosis, Vibration analysis, acoustic emission analysis, multi-sensor signal processing, wavelet transform, CNN