



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 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](#)

공학석사 학위논문

공작기계 설비 건전성 진단을 위한
신호처리 알고리즘 개발 및
딥러닝 기반의 상태 분류 알고리즘에
관한 연구

Development of a Signal Processing Algorithm
and Research on Deep Learning-Based Condition
Classification for Machine Tool Health Diagnosis

울산대학교 대학원

전기전자컴퓨터공학과

한재민

공작기계 설비 건전성 진단을 위한
신호처리 알고리즘 개발 및
딥러닝 기반의 상태 분류 알고리즘에
관한 연구

지도교수 김종면

이 논문을 공학석사 학위 논문으로 제출함




2025년 2월

울산대학교 대학원

전기전자컴퓨터공학과

한재민

한재민의 공학석사 학위 논문을 인준함

심사위원장	조 동 식	
심사위원	김 종 면	
심사위원	권 영 근	

울 산 대 학 교 대 학 원

2025 년 02 월

[국문 요약]

공작기계 설비 건전성 진단을 위한 신호처리 알고리즘 개발 및 설명 가능한 딥러닝 기반의 상태 분류 알고리즘에 관한 연구

본 연구는 글로벌 제조업의 경쟁력 강화와 국내 제조 산업의 디지털 전환에 발맞춰 공작기계 설비에서 발생하는 주요 결함을 효과적으로 진단하고 효율적으로 데이터를 관리하기 위한 회전 성분 기반의 신호처리 알고리즘을 제안한다. 또한 제안한 신호처리 알고리즘을 활용한 딥러닝 기반의 상태 분류 알고리즘 및 설명 가능한 인공지능에 대한 연구를 수행하였다. 연구에서 활용된 데이터는 MCT 테스트베드를 통해 구축되었으며, 설비에서 발생할 수 있는 정상, 베어링 결함, 기어 결함, 공구 결함 상태를 모사한 뒤 다양한 절삭 속도와 환경에서 재료를 가공하는 동안 수집하였다. 이후 취득된 데이터를 각 결함별로 시계열 분석과 속도, 가속도, 포락 스펙트럼 분석을 통해 절삭 및 결함과 관련된 성분들을 집중적으로 분석하였다.

연구에서 제안하는 신호처리 기법은 회전 성분 기반의 처리 방식을 통해 절삭 공정에서 발생하는 저주파 영역의 주요 배수 성분의 특성을 보존하면서 대용량 진동 데이터를 효과적으로 압축하는 목적으로 설계되었다. 이는 저주파 영역에서는 세밀한 샘플링을, 고주파 영역에서는 넓은 샘플링을 적용하여 절삭 공정의 특징을 유지하면서도 저장 비용을 낮출 수 있는 효율적인 데이터 관리 방식을 제공한다. 또한 특정 인자를 통해 통합된 데이터 구조를 제공하여, 서로 다른 설비와 환경에서 수집된 데이터를 동일한 형식으로 변환할 수 있는 장점을 지니며 산업 간 데이터 표준화의 기반을 마련한다. 딥러닝 알고리즘으로는 결함 진단 분야에서 널리 활용되는 1D CNN 과 TabNet 을 주파수 도메인에서 활용하여 연구에 적용한다. 1D CNN 은 필터 기반의 특징 추출 메커니즘을 통한 학습을 제공한다. TabNet 은 Sparse Attention 메커니즘을 활용하여 데이터의 주요 특징을 단계적으로 선택하여 학습하고, 설명 가능성을 제공함으로써 예측 결과의 신뢰성을 높일 수 있다. 특히 TabNet 의 특징 선택 메커니즘과 제안하는 회전 성분 기반의 신호처리를 통해 결함 분류에 활용되는 중요한 회전 성분의 특징을 효과적으로 학습하고, 결함 분류에 중요하게 사용된 회전 성분의 특징들을 시각적으로 제시하여 설명 가능성을 제공하는 것을 목적으로 한다.

연구의 결과로 제안된 신호 처리 알고리즘과 딥러닝 알고리즘의 결합이 MCT 설비의 결함 분류 문제에 효과적으로 작용함을 확인하였다. 제안된 신호처리 적용 유무에 따라 각 학습 모델의 결과를 분석하였을 때, 제안된 신호처리 데이터 셋을 통해 학습된 1D CNN 과 TabNet 모델 모두 결함 분류 성능이 향상되었다. 특히 TabNet 의 경우 신호처리가 적용되지 않은 단순한 주파수 데이터로 학습한 경우 비교적 낮은 검증 정확도와 높은 변동성을 보였다. 하지만 신호처리가 적용된 데이터를 학습에 사용했을 때 Sparse Attention 메커니즘을 통해 특정 회전 성분의

특징을 효과적으로 학습하여 높은 성능 개선을 보였다. 센서의 설치 위치 및 민감도와 절삭 속도 차이에 따른 분석에서도 TabNet 알고리즘과 제안된 신호처리의 결합이 큰 성능 향상을 보이는 것을 확인했다.

설명 가능성에 대한 분석에서는 TabNet 과 제안된 신호처리를 통해 회전 성분의 특징 중요도를 시각적으로 확인하였다. 또한 결함 별로 TabNet 의 Step 이라는 학습 단위에서 선택된 특징의 경향성을 분석하는 것이 가능하였다. 이는 기존의 블랙박스 특성의 딥러닝 모델과 차별화되는 특징으로 각 단계별로 중요한 회전 성분의 특징 구간을 식별하고 결함 분류에 대한 설명 가능성을 제시한다.

결론적으로, 제안된 신호처리 알고리즘과 딥러닝 알고리즘의 결합이 MCT 설비에서의 결함 진단에 효과적으로 작용하는 것을 입증하였다. 또한 TabNet 모델의 설명 가능성은 결함 진단 분야에서 단순한 예측 성능을 넘어 중요한 회전 성분 특징을 시각적으로 분석하고, 결함 원인에 대한 이해를 증진시키는 데 기여할 수 있음을 보여주었다. 이러한 결과는 제조 산업의 디지털 전환 및 스마트 팩토리 발전에 있어 실질적인 데이터 활용 방안을 제시하며, 다양한 설비와 환경에서의 적용 가능성을 높이는 신뢰성 있는 진단 모델 개발에 기여할 것으로 기대된다.

주제어:

공작기계(Machine Tool), 상태 분류(Condition Classification),
신호처리(Signal Processing), 딥러닝(Deep Learning), TabNet, 1D-CNN,
설명가능한 인공지능(Explainable AI, XAI)

목차

[국문 요약]	i
[목차]	iii
[그림 목차]	v
[표 목차]	vii
1. 서론	1
1.1. 연구 목적 및 필요성	1
1.2. 논문의 구성	2
2. 관련 연구	3
2.1. 설비의 상태진단	3
2.2. 진동 신호 분석	4
2.2.1. 시계열 분석과 주파수 분석	5
2.2.2. 포락 분석(Envelope) 분석	7
2.2.3. 회전 성분 단위 (X 성분)	7
2.3. 딥러닝	9
2.3.1. CNN	9
2.3.2. 1D CNN	10
2.3.3. TabNet	11
2.3.3.1 Feature Transformer	12
2.3.3.2 Attentive Transformer	13
3. 공작기계 설비 데이터 수집 및 분석	15
3.1. MCT 설비 구조 및 고장 유형	15
3.2. 테스트 베드 구조 및 실험 설정	15
3.3. 데이터 수집	18
3.4. 수집 신호 분석	19
3.4.1 정상 신호 분석	20
3.4.2 베어링 결함 신호 분석	21
3.4.3 기어 결함 신호 분석	22
3.4.2 공구 결함 신호 분석	23

4. 제안하는 신호처리 방법 및 데이터 구축	25
4.1. 회전 성분 기반의 구간 생성 및 특징 추출 알고리즘	25
4.2. 제안된 신호처리 적용 유무의 데이터 비교	29
4.2.1. 1Hz 단위의 가속도 주파수 데이터.....	29
4.2.2. 신호처리를 통해 압축 및 변환된 주파수 데이터.....	30
4.2.3. 신호처리에 따른 용량 및 특징 비교	32
4.3. 데이터 증강 기법 적용	33
5. 실험	34
5.1. 신호 처리 및 학습 모델의 파라미터 설계	34
5.1.1. 제안된 신호처리에 대한 파라미터 설정.....	34
5.1.2. 1D CNN의 파라미터 설정.....	35
5.1.3. TabNet의 파라미터 설정	35
5.2. 교차 검증을 활용한 결함 분류 실험 설계	36
5.3. 실험 결과	37
5.3.1. 1Hz 단위의 단순 가속도 주파수 데이터	37
5.3.2. 제안된 신호처리로 압축 및 변환된 주파수 데이터.....	38
5.4. 실험 결과 분석.....	39
5.4.1. 학습 알고리즘과 신호 처리 유무 간의 검증 성능 비교	39
5.4.2. 센서 설치 위치 및 종류 간의 검증 성능 비교.....	40
5.4.3. 학습 데이터 셋 종류별 검증 성능 비교.....	41
5.5. TabNet의 Feature Importance	42
5.5.1. 전역적 특징 중요도	42
5.5.2. Step 단위의 특징 중요도	44
6. 결론	45
[참고 문헌]	viii
[영문 요약]	x

그림 목차

그림 2- 1. 수리 비용과 정비 비용 간의 관계.....	3
그림 2- 2. 회전 설비의 각 결함 별 베어링 신호 양상	5
그림 2- 3. 푸리에 변환과 역 변환 개략도[15]	6
그림 2- 4. 포락 분석의 효과 예시.....	7
그림 2- 5. 배수 성분과 사이드밴드 성분의 검출 예시	8
그림 2- 6. CNN 모델 구조	9
그림 2- 7. 1D CNN Feature Extraction 과정.....	10
그림 2- 8. TabNet 모델의 기본 구조.....	11
그림 2- 9. TabNet 의 Feature Transformer.....	12
그림 2- 10. TabNet 의 Attentive Transformer	13
그림 2- 11. Sparsemax 와 SoftMax 의 비교[21]	13
그림 2- 12. TabNet 의 Mask 기반의 설명 가능성[10].....	14
그림 3- 1. 실험에 사용된 MCT 테스트베드.....	16
그림 3- 2. 실험에 사용된 결함 요소	17
그림 3- 3. 실험에서 사용된 피 절삭물과 가공 형태.....	18
그림 3- 4. 센서 별 주파수 감도 편차 [22].....	19
그림 3- 5. 정상 신호의 시계열 및 스펙트럼 분석	20
그림 3- 6. 베어링 결함 신호의 시계열 및 스펙트럼 분석	21
그림 3- 7. 기어 결함 신호의 시계열 및 스펙트럼 분석.....	22
그림 3- 8. 공구 결함 신호의 시계열 및 스펙트럼 분석 1.....	23
그림 3- 9. 공구 결함 신호의 시계열 및 스펙트럼 분석 2.....	23
그림 4- 1. 프로세스 다이어그램	25
그림 4- 2. 데이터 추출 방식	27
그림 4- 3. 결함 및 센서 별 1hz 단위의 가속도 주파수 데이터 셋.....	29
그림 4- 4. 신호처리로 변환된 정상 신호의 예시.....	30
그림 4- 5. 신호처리로 변환된 베어링 결함 신호의 예시.....	30
그림 4- 6. 신호처리로 변환된 기어 결함 신호의 예시	31
그림 4- 7. 신호처리로 변환된 공구 결함 신호의 예시	31
그림 4- 8. 신호 처리 적용 전후의 용량 비교.....	32
그림 4- 9. 데이터 증강 예시	33

그림 5- 1. 실험에 사용된 데이터 셋의 모습.....	36
그림 5- 2. 학습 알고리즘 별 성능 비교.....	39
그림 5- 3. 센서 설치 위치 별 성능 비교.....	40
그림 5- 4. 학습 데이터 종류 별 성능 비교.....	41
그림 5- 5. 모터 데이터로 학습된 모델의 전체 Feature Importance.....	42
그림 5- 6. 스핀들 데이터로 학습된 모델의 전체 Feature Importance ...	43
그림 5- 7. 모터 학습 모델의 Step 별 Feature Importance.....	44
그림 5- 8. 스핀들 학습 모델의 Step 별 Feature Importance.....	44

표 목차

표 3- 1. 실험 시나리오.....	18
표 4- 1. 구간별 Peak 추출 후 데이터 셋 형식.....	27
표 4- 2. 최종 결과 데이터 셋 형식.....	28
표 4- 3. 신호 처리 적용 전후의 용량 비교.....	32
표 5- 1. 학습에 사용된 신호 처리 파라미터.....	34
표 5- 2. 학습에 사용된 TabNet 의 파라미터.....	35
표 5- 3. 같은 운전 조건 내에서의 교차 검증 방식 예시.....	36
표 5- 4. 신호 처리가 적용되지 않은 모터 데이터로 학습한 결과.....	37
표 5- 5. 신호 처리가 적용되지 않은 스핀들 데이터로 학습한 결과.....	37
표 5- 6. 신호 처리가 적용된 모터 데이터로 학습한 결과.....	38
표 5- 7. 신호 처리가 적용된 스핀들 데이터로 학습한 결과.....	38

1. 서론

1.1. 연구 목적 및 필요성

글로벌 제조업 경쟁력 강화 트렌드에 맞춰 제조 산업에서는 디지털 전환(Digital Transformation)과 자동화(Automation)를 접목하여 산업 구조를 혁신하고, 부가가치율을 끌어올리는 것을 목표로 하고 있다[1]. 이 때 생산 성능을 극대화하고 유지보수 비용을 절감하기 위한 예지보전은 필수적인 기술로 자리 잡고 있다[2]. 예지보전의 필요성은 설비에서 발생하는 고장이 단순히 생산성 저하를 초래하는 것뿐만 아니라 장기적인 운영 중단 및 심각한 재정적 손실을 발생시킬 수 있다는 점에서 더욱 주목받는다[3]. 제조 설비 중 하나인 공작기계의 경우 절삭 공구의 상태에 따라 제품의 품질 저하나 불량품의 대량 발생이 가능하고, 베어링 또는 기어 등의 부품 고장은 생산성 저하와 설비의 고장을 초래하여 전체 공정에 심각한 영향을 미칠 수 있다. 이 때문에 공작기계의 고장진단과 인공지능 기술을 접목한 여러 연구가 선행되어왔다. 이러한 연구로는 기계 학습과 수집된 센서 값을 활용한 특징값 기반의 공구 마모도 예측[4], 딥러닝 기법을 활용한 베어링 고장 진단[5], 연속 웨이블릿 변환 등의 신호처리를 통한 공구 상태 분류의 성능을 향상시킨 연구[6] 등이 수행되었다. 이러한 연구와 알고리즘들이 좋은 성능과 결과를 나타내었으나, 이를 실제 산업 현장에서 적용하기에는 몇 가지 한계점이 존재한다.

먼저 학습된 모델의 일반화 문제이다. 실험적인 환경에서 높은 성능을 보인 모델이 실제 산업 현장에서 동일한 성능을 나타내지 못하는 경우가 많다. 이는 각 제조 환경과 설비의 구조, 공정의 방식, 노이즈 성 신호의 포함 유무 등의 차이에서 기인하며 실제 현장 데이터와 학습 데이터 간의 차이가 두드러질수록 모델의 일반화 능력이 떨어진다. 이에 따라 현재의 예지보전 시스템은 각 제조업체의 상황에 맞게 맞춤형으로 설계되고, 모델의 파라미터들의 조정이 요구되는 상황이다.

두 번째로, 산업 현장에서 각 설비의 데이터를 지속적으로 저장 및 관리하는데 제약이 존재한다. 센서의 원시 데이터는 일반적으로 매우 큰 파일의 형태이며 이를 매초, 매분 저장하고 관리하는 것은 막대한 관리 비용을 필요로 한다. 하지만 불량 데이터는 발생 빈도가 낮고 발생 시점의 예측이 어려운 경우가 많아 이를 포착하기 위해서는 적절한 주기에 데이터를 수집 및 분석하는 것이 요구된다. 따라서 적절한 데이터의 관리 주기를 선정하는 지식과 시스템 구축이 요구되는 상황이다[7].

마지막으로 딥러닝과 같은 복잡한 알고리즘은 높은 정확도를 제시하나, 블랙박스과 같은 특성을 지니고 있어 신뢰성을 제시하기에 한계점이 있다. 예지보전 시스템의 특성상 공정의 다운타임 발생 시 생산성 및 비용에 막대한 손실을 끼칠 수 있기 때문에 유지보수 결정을 내리는 데 있어 엔지니어들에게 큰 부담이 될 수 있다[8].

이러한 한계점들을 해결하기 위해서 본 논문에서는 회전 성분 기반의 신호처리와 이를 활용한 딥러닝 알고리즘을 제안한다. 제안된 신호처리 방식은 회전 성분을 기반으로 데이터를 압축하여 절삭 공정의 배수 성분의 신호 특성을 보존하면서 유의미한 압축을 수행한다. 이때 절삭 공정과 관련된 저주파의 특성은 정밀하게

샘플링하고 노이즈에 민감한 고주파의 특성은 넓게 샘플링하여 데이터를 압축한다. 이를 통해 대용량의 진동 스펙트럼 데이터를 효과적으로 압축하여 저장 비용을 낮출 수 있을 것으로 기대한다. 또한 제안된 신호처리 방식에서는 특정 인자를 통해 통합된 구조를 제공하고 서로 다른 환경에서 수집된 데이터를 동일한 형식으로 변환할 수 있는 장점을 지닌다. 이는 제조 산업 환경에서의 데이터 호환성을 높이고, 산업 간의 데이터 표준화 기반을 마련하는데 역할을 할 수 있다.

딥러닝 모델에서는 기존의 고장 진단 분야에서 많이 활용되고 있는 1D CNN 알고리즘[9]과 함께 TabNet 알고리즘[10]을 주파수 도메인에서 활용하는 것을 제안한다. TabNet 알고리즘은 각 단계에서 주목할 특징을 효과적으로 학습하도록 설계된 모델로, 데이터의 중요한 부분을 선택적으로 학습하는데 뛰어난 성능을 발휘한다. 또한 설명 가능성을 제공하므로 모델 학습에 기여한 특징의 중요도를 제시하여 학습 결과의 신뢰성을 높일 수 있다.

연구의 최종 목표는 제안하는 신호처리 알고리즘과 2 가지의 딥러닝 알고리즘을 활용하여 MCT 설비의 효과적인 결함 분류를 목적으로 한다. MCT 테스트 베드를 통해 다양한 운전 환경에서 데이터를 취득하고 모델을 학습한다. 제안된 신호처리 알고리즘의 적용 유무에 따른 각 학습 모델의 결함 분류 성능과 센서 종류, 질속 속도 등 다양한 실험 환경 변화에서의 일반화 능력을 평가한다. 또한 TabNet 알고리즘의 설명 가능성과 제안된 신호처리를 함께 적용함으로써 결함 분류에 활용된 각 회전 성분 특징의 중요도를 시각적으로 분석하고, 각 학습 단계에서 중요하게 선택된 회전 성분 특징 간의 경향성을 확인한다.

본 연구는 제조 산업의 디지털 전환과 예지보전 시스템 고도화에 중요한 역할을 수행할 것으로 기대된다. 제조산업에서 활용 가능한 회전 성분 기반의 신호처리 알고리즘과 인공지능의 일반화 능력 검증 및 설명 가능성을 개선하여 진동 센서의 데이터 관리 비용 문제 및 딥러닝 모델의 특징 중 하나였던 블랙박스 모델의 한계 점을 해결하고자 한다. 이를 통해, 스마트 제조 환경에서 실질적이고 효과적인 예지보전 시스템 구현 가능성을 전망한다.

1.2. 논문의 구성

본 논문은 다음과 같이 구성되어 있다. 2 장의 관련 연구에서는 설비의 상태 진단과 진동 분석 그리고 사용된 딥러닝 알고리즘들에 대해 기술한다. 3 장에서는 공작기계 설비의 구조와 데이터 수집 방법에 대해 기술하고 수집된 데이터를 분석한다. 4 장에서는 연구에서 제안하는 신호처리 방법에 대해 기술한다. 5 장에서는 학습에 사용되는 모델의 파라미터를 설정하고 모델 학습 및 실험 결과를 분석한다. 6 장에서 본 논문의 결론에 대해 서술한다.

2. 관련 연구

2.1. 설비의 상태진단

기계 설비는 여러 기계요소로 구성되며 다양한 구성 요소들은 각자의 목적에 맞게 상호작용하면서 전체 시스템을 구성한다. 이러한 기계는 시간이 지남에 따라 부하를 받고 피로가 누적되기 때문에 각각의 구성요소가 마모되거나 손상될 수 있고, 이는 기계 설비 전체의 성능 저하와 고장을 초래할 수 있다. 이때 설비의 상태가 심각하게 악화되기 전에 진단 및 정비를 실시하여 설비의 다운 타임을 최소화하고 장기적인 성능 유지에 중요한 기초를 하는 것을 예지보전(Predictive Maintenance, PdM)이라 한다. 예지보전은 산업 분야에서 설비의 상태를 지속적으로 모니터링하고, 데이터를 분석하여 잠재적인 문제를 사전에 예측하고 필요한 조치를 취함으로써 설비의 효율성을 최대화하는 유지보수 전략을 말한다. 그림 2-1 과 같이 예방적 유지보수(PM)와 예지보전(PdM) 그리고 사후 보전(CM)은 설비의 정비 주기와 비용 간의 상충 관계를 지니고 있다. 유지보수 간격을 좁히면 수리 비용 측면에서는 유리하지만 예방 비용은 증가하게 된다. 반면 유지보수 간격을 넓히면 고장 발생 확률 증가로 수리 비용과 다운 타임에 의한 막대한 생산 손실 비용이 발생한다. 이러한 이유로 PM 과 CM 간의 적절한 균형을 맞추는 것이 필요하며, 센서 기술과 인공지능을 활용한 PdM 은 설비 상태를 실시간으로 모니터링하여 데이터 기반 의사결정을 가능하게 함으로써 예방 비용을 최적화하는 효과적인 접근 방법이 될 수 있다. 이를 위해서는 설비의 건전성을 진단하기 위한 진단 시스템과 데이터 취득을 위한 센싱 시스템이 요구되는데, 산업 현장에서는 온도, 진동, 전류, 압력 등의 다양한 센서들이 활용되고 있다. 이 중 진동 센서는 설비의 다운타임 최소화나 미세한 결함 탐지, 비용 효율성 등의 장점을 지니며 유용한 유지보수 전략으로 자리 잡고 있다[11].




그림 2- 1. 수리 비용과 정비 비용 간의 관계

2.2. 진동 신호 분석

진동이란 물체가 중심점을 기준으로 반복적인 운동을 하는 현상을 말한다, 이러한 진동 신호는 설비의 감시 및 진단에 있어서 중요한 역할을 하며 이를 통해 설비의 건전성을 평가하는 다양한 연구가 선행되어 왔다. 이러한 진동은 변위, 속도, 가속도라는 세 가지의 진폭 단위로 표현될 수 있다.

먼저 변위 진동은 물체가 기준점으로부터 얼마나 떨어져 있는지 나타내는 지표로 진동의 크기를 가장 직관적으로 나타낸다. 물리적 크기를 파악하는데 유용하며, 설비의 동작 상태를 평가하는데 유의미하다. 변위 진동은 t 시간에서의 변위 값을 다음과 같은 식(1)으로 나타낼 수 있으며 X_0 는 진폭, $2\pi f$ 는 각속도, t 는 시간 ϕ 는 초기 위상을 나타낸다.

$$x(t) = X_0 \cdot \sin(2\pi ft + \phi_0) \quad (1)$$

속도 진동은 물체가 진동하는 동안 특정 위치에서의 순간 속도를 나타낸다. 이는 운동 에너지와 관계가 높으며 설비의 마모나 손상 정도를 예측하는데 활용된다. 변위의 미분을 통해 속도를 나타낼 수 있으며 이는 \cos 함수로 변환되어 주기 함수의 형태로 나타나며 식(2)와 같이 나타낸다.

$$v(t) = \frac{dx}{dt} = 2\pi f \cdot X_0 \cdot \cos(2\pi ft + \phi_0) \quad (2)$$

가속도 진동은 물체의 순간 속도 변화율의 크기로 진동이 발생하는 동안 작용하는 힘의 변화를 나타낸다. 설비의 건전성 평가에서 가속도는 주로 고주파에서 발생하는 작은 결함이나 불균형을 탐지하는데 효과적으로 작용한다고 알려져 있다. 가속도는 속도의 미분을 통해 나타낼 수 있으며 \sin 함수 형태의 수식으로 정리되어 식(3)과 같이 나타낼 수 있다.

$$a(t) = \frac{d^2x}{dt^2} = -(2\pi f)^2 \cdot X_0 \cdot \sin(2\pi ft + \phi_0) \quad (3)$$

위와 같이 변위, 속도, 가속도는 미분 및 적분의 관계로 연결되어 상호 변환이 가능하다. 또한 변위는 저주파 대역에서 설비의 구조적 상태, 속도는 중간 주파수 대역에서 에너지 전달과 마모 상태, 가속도는 고주파 대역에서 미세한 결함이나 충격성 진동을 탐지하는 데 효과적이다. 따라서 이러한 관계 및 특징을 활용하여 설비 진단 및 상태 평가에 적절한 진동 단위를 선택한다면 보다 효율적이고 정밀한 평가가 가능하다.

2.2.1 시계열 분석과 주파수 분석

시계열 분석은 진동 센서에서 시간 단위로 수집된 데이터의 진동 크기를 분석하는 것을 말한다. 시간 영역에서 진동을 분석하는 것은 인간이 이해하기 직관적이며, 즉각적인 이상 징후를 탐지하는데 효과적이다. 시간 영역 분석에는 주기성을 가지는 신호나 과거보다 진동의 크기가 높고 낮아졌는지 등의 트렌드를 분석하여 기계의 결함 원인을 분석할 수 있다. 그림 2-2 는 회전 설비의 베어링 결함 신호를 취득하여 시간 영역에서 나타낸 예시이다. 정상 신호에서는 진동의 크기가 일정하며 파형 또한 두드러지지 않고 안정된 모습이다. 내륜 결함의 경우 주기적으로 큰 진폭 값이 발생하며 베어링 하중이 생길 때 마다 결함과 충격으로 인해 진동이 발생하는 것으로 추측된다. 외륜 결함은 복잡한 패턴을 보이며 진폭이 더 크고 주기적으로 변동하는 특징을 가진다.

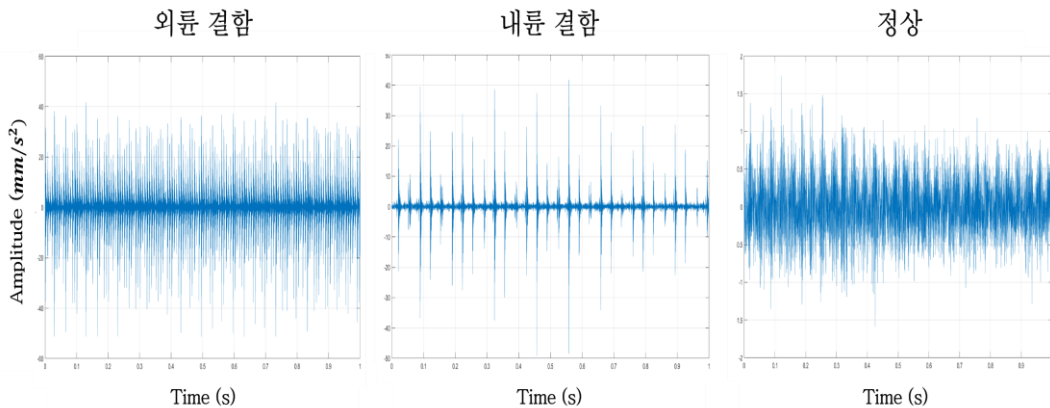


그림 2- 2. 회전 설비의 각 결함 별 베어링 신호 양상

주파수 영역 분석은 일반적으로 시간 파형으로 취득된 데이터를 푸리에 변환(Fourier Transform)을 사용하여 주파수 영역으로 변환한 뒤 분석을 수행한다. 푸리에 변환은 시간 영역에서는 쉽게 분석할 수 없는 신호를 sin 과 cos 형태의 주파수 성분으로 분해할 수 있도록 한다[12]. 이를 통해서 특정 주파수에 발생하는 진동의 성분을 분해하여 기계 설비의 결함을 진단하는데 유용하게 사용되고 있다. 푸리에 변환을 수식으로 나타내면 식 4 와 같이 나타낼 수 있다.

$$F(u) = \int_{-\infty}^{\infty} f(x)e^{-j2\pi ux} dx \quad (4)$$

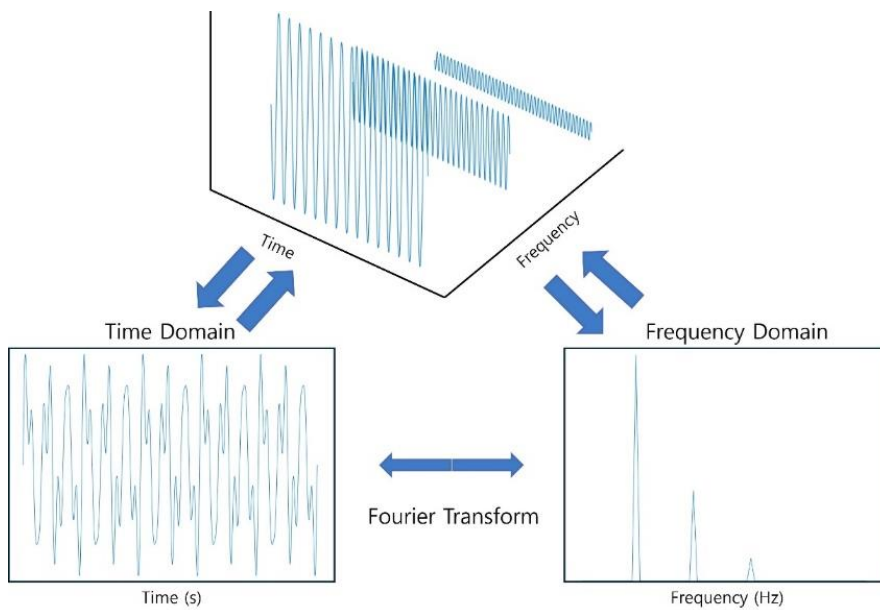


그림 2- 3. 푸리에 변환과 역 변환 개략도[15]

그림 2-3 과 같이 푸리에 변환을 통해 신호의 주파수 성분을 분리하여 분석할 수 있다는 점은 설비 진단에서 중요한 역할로 작용한다. 예를 들어, 기계의 회전축에서 발생하는 언밸런스(unbalance) 결함은 일반적으로 회전 주파수와 동일한 주파수에서 강한 진동이 나타난다. 회전축이 약간 기울어지거나 편심이 발생한 경우, 일반적으로 회전축의 두 부분이 서로 다른 방향으로 한 주기에 두 번의 힘을 받으므로 회전 주파수의 2 배의 주파수에서 강한 진동이 나타나게 된다. 이 외에도 결함 주파수 및 주파수 패턴을 통해 설비를 진단하는 수식들이 정립되었으며 아래는 그 예시 중 일부이다.

$$\begin{aligned}
 BPF0 &= \frac{N}{2} f_r \left(1 - \frac{d}{D} \cos \phi\right) & : \text{베어링 외륜 결함 주파수} \\
 BPF1 &= \frac{N}{2} f_r \left(1 + \frac{d}{D} \cos \phi\right) & : \text{베어링 내륜 결함 주파수} \\
 GMF &= N f_r & : \text{기어 물림 주파수} \\
 BPF &= N_b f_r & : \text{블레이드 통과 주파수}
 \end{aligned} \tag{5}$$

d : 볼 직경, N : 볼 갯수, f_r : 축 속도, N_b : 팬 블레이드 수, D : 기본열 피치 직경, ϕ : 접촉각

2.2.2 포락(Envelope) 분석

포락(Envelope) 분석 기법은 센서 신호, 주가, 음성 데이터와 같은 다양한 분야에서 유용하게 활용되고 있는 신호처리 기법이다. 이는 주로 신호의 진폭 변동을 분석하여 특정 패턴이나 이상 현상을 감지하는 데 사용된다. 예를 들어 회전기기의 베어링에서 결함이 발생되면 주기적으로 강한 충격과 신호가 발생하고 이는 기저 진동 신호의 주기적인 피크 상승을 유발할 수 있다. 즉 고주파의 기저 진동 신호가 저주파 충격 신호에 의해 진폭 변조되면서 발생하고 충격 신호의 주파수는 주파수 영역에서 기저 진동 신호를 중심으로 사이드밴드(Side-Band)의 형태로 나타나게 된다. 그러나 기저 진동 주파수는 일반적으로 복잡한 진동 환경에서 단일 주파수로 존재하지 않기 때문에, 변조된 신호에서 충격 주파수를 직접 식별하는 것이 어려울 수 있다. 이러한 경우 포락 분석 기법을 사용하여 신호를 분석할 수 있다. 포락 분석은 고주파 신호의 진폭 변동을 추출하여 저주파 신호로 변환하는 과정으로, 이는 충격 신호와 같은 고주파 성분을 보다 쉽게 식별할 수 있도록 해준다[13].




그림 2- 4. 포락 분석의 효과 예시

2.2.3 회전 성분 단위 (X 성분)

회전 설비에서는 회전 성분과 관련된 분석을 통해 결함 진단이 빈번하게 이루어진다. 이때 Hz 단위 이외에 회전 성분을 나타내는 X 라는 단위를 사용하기도 한다. 이는 회전 성분의 배수를 나타내는 단위로 회전 속도 즉, 기본(회전) 주파수의 배수 성분을 의미한다. 예를 들어 스핀들이 3600 RPM 으로 회전한다면 스핀들의 1X 는 3600 을 60 분으로 나눈 60 Hz, 2X 는 120Hz 로 변환될 수 있다. 이러한 회전 성분인 X 성분은 진동 분석에서 중요한 지표로 사용될 수 있으며 특정 X 성분의

진동이 커지는 경우를 분석하여 기계의 상태를 분석 및 진단할 수 있다. 설비의 신호를 분석할 때 1X 성분의 진동이 증가한다면 불균형(Unbalance) 문제를 2X 성분의 진동이 증가한다면 정렬 불량(Misalignment)이나 축 결함(Shaft Defects) 등의 문제를 의심할 수 있다. 또한 X 성분과 함께 그 주변에 양옆으로 발생하는 사이드밴드(Side Band) 또한 진동 분석에서 자주 활용되며, 이러한 신호는 기어 결함이나 베어링 결함 등의 복잡한 기계적 문제를 진단하는데 유용하게 사용될 수 있다. 그림 2-5 는 진동의 회전 주파수인 1X 성분과 2X 성분 그리고 X 성분 양 옆으로 발생한 사이드 밴드 신호를 모사하여 나타낸 예시 신호이다. 시계열 신호에서는 관측할 수 없던 패턴이 주파수 영역으로 변환되면 회전 성분과 사이드 밴드 성분들이 크게 포함되어 있는 것을 확인할 수 있다. 이러한 예시처럼 회전 설비에서 수집된 진동 신호를 주파수 도메인으로 분석하면, 회전 성분과 사이드밴드 등의 특징과 패턴을 통해 결함을 조기에 진단할 수 있고, 이는 설비의 안정성을 높이고 예지 보전 등에서 효과적으로 활용될 수 있다[14].

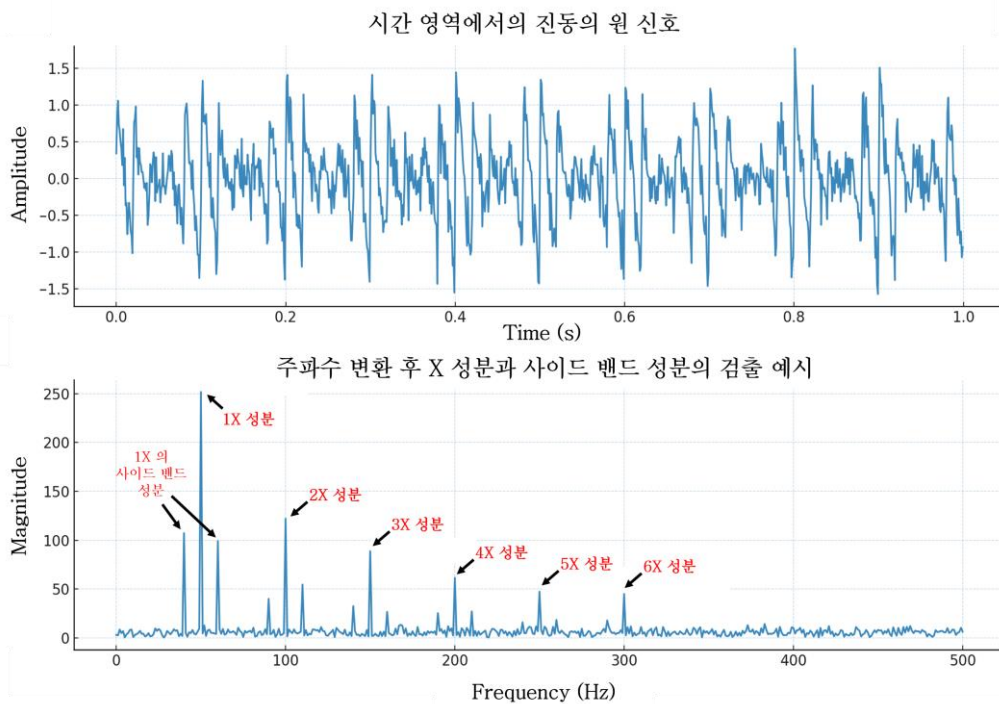


그림 2- 5. 배수 성분과 사이드밴드 성분의 검출 예시

2.3. 딥러닝

2.3.1. CNN

CNN(Convolutional Neural Network)은 인간의 시신경 구조를 모방한 딥러닝 모델로 주로 이미지나 텍스트 등 다양한 유형의 데이터에서 활용 가능하며 특징을 추출하여 학습에 활용하는데 특화된 신경망이다[16]. CNN은 여러 개의 Convolution Layer를 통해 입력 데이터를 처리하는데 각 레이어에서 커널 함수를 기반으로 데이터 내의 고유한 특징을 추출하여 다음 층으로 전달하면서 학습을 진행하게 된다. 여기서 Convolution이란 특징을 추출하기 위해 입력 데이터에 필터(커널) 연산을 적용하는 것을 의미하며, CNN에서는 입력 데이터에 필터가 stride 값만큼 이동하면서 해당 구역과 필터 간의 합성 곱 연산을 수행하면서 결과를 생성한다. 입력 데이터의 전체 영역을 탐색하며 생성한 결과를 특징 맵(feature map)이라고 하며, 각 Convolution Layer에서는 입력 데이터에서 특정 패턴을 감지하고 이를 추출하게 된다. 주로 층이 깊어질수록 더욱 복잡한 패턴을 학습하는 경향이 있으며 풀링 계층(Pooling Layer)은 특징 맵의 크기를 줄이고, 불필요한 정보 제거 및 계산 효율성을 향상시킨다. 풀링의 방법에는 다양한 방법이 있는데 주로 사용되는 방법으로는 최댓값을 추출하는 Max pooling이나 평균을 구하여 추출하는 Average pooling 등이 있다. 특징 추출 단계를 거친 뒤, 분류 단계에서는 데이터를 Flatten 계층을 통해 1차원 벡터로 변환하고 Fully Connected 계층으로 전달한다. 이 단계에서는 이전 단계에서 얻은 특징들을 입력으로 가중치 파라미터들을 조절하며 네트워크의 예측 성능을 최적화한다. 그 후 SoftMax와 같은 활성화 함수를 통해 확률 분포를 계산하여 분류가 가능하다. 이러한 CNN의 학습 과정은 그림 2-6과 같이 특징 추출과 분류 단계로 나누어 학습 과정을 나타낼 수 있다.

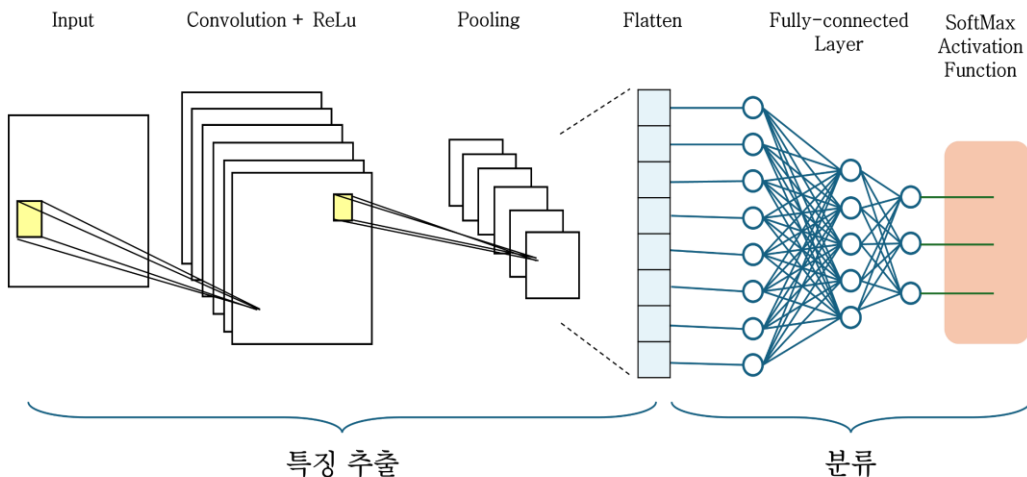


그림 2- 6. CNN 모델 구조

2.3.2. 1D CNN

1D CNN(1-Dimension Convolutional Neural Network)은 CNN 모델 구조의 변형 모델로 시계열 데이터 또는 순차적인 데이터에서 좋은 성능을 보이는 모델로 알려져 있다[17]. 1D CNN은 기존 CNN 모델이 2차원의 이미지 데이터에서 활용되던 것과 달리, 입력 데이터가 1차원 배열(시계열 데이터나 신호형식의 데이터)인 경우 주로 활용된다. 1D CNN의 가장 큰 특징은 1차원 커널을 사용하여 단일 차원에 걸쳐 이동하면서 전체 신호에서 국소적인 특징을 학습한다는 점이다. 또한 기존의 CNN보다 파라미터 수가 적기 때문에 학습 비용 측면에서 효율적이며, 과적합을 방지하는데 유리하다. 실제로 예지 보전 분야에서 1D CNN을 활용하여 결함이 발생 시 특정 위치에 주파수 성분들이 강하게 나타나는 국소적 특징을 통해 성공적으로 결함을 감지하거나 예측 정확도를 높인 사례가 있다[18].

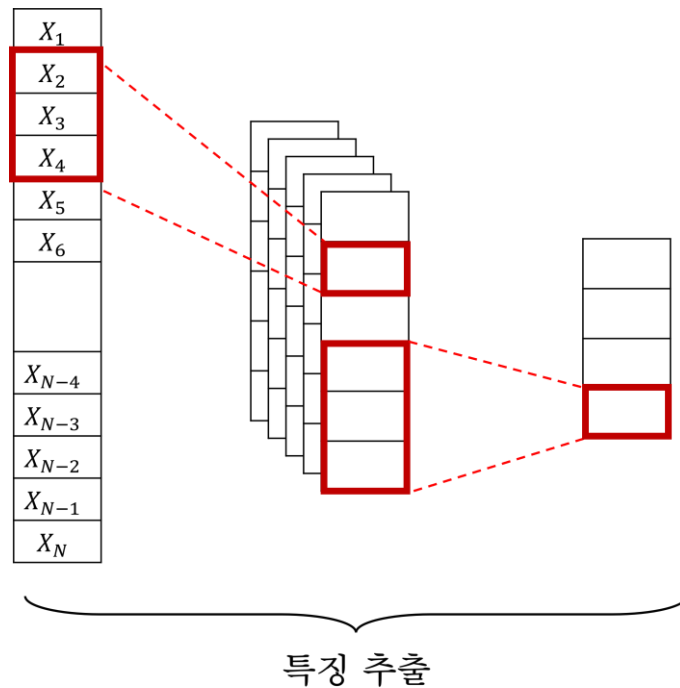


그림 2- 7. 1D CNN Feature Extraction 과정

2.3.3. TabNet

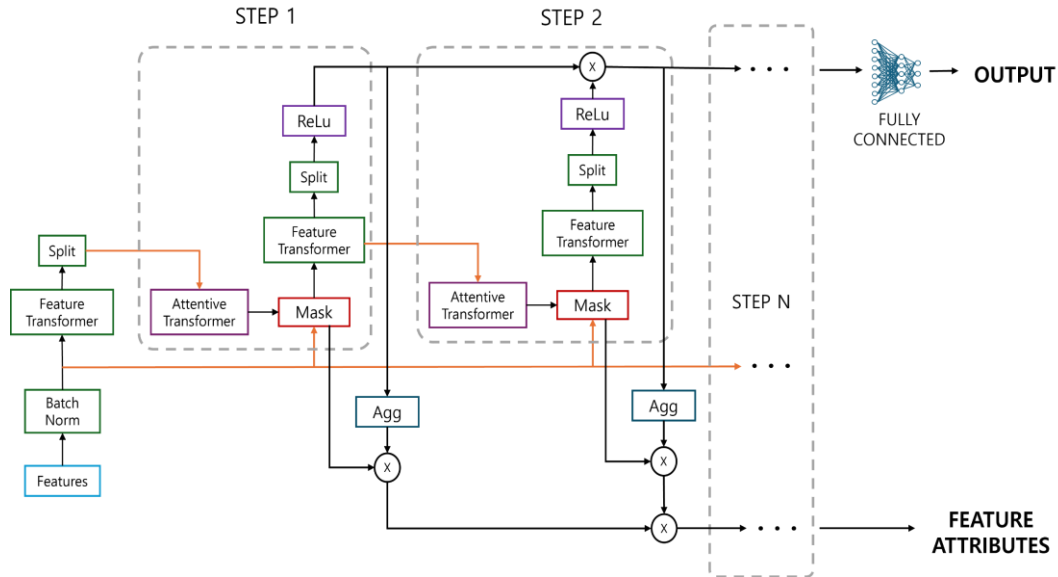


그림 2- 8. TabNet 모델의 기본 구조

TabNet 은 정형 데이터를 처리하기 위해 제안된 딥러닝 기반의 엔드 투 엔드 모델로, Gradient-based Learning 을 통해 최적화된다. 이 모델은 Tree 기반 모델의 변수 선택(Feature Selection) 방식을 딥러닝 네트워크 구조에 통합하여, 정형 데이터 처리에 특화된 알고리즘이다. 또한 Sequential Attention Mechanism 을 사용하고, 각 층의 단계마다 어떤 특징을 사용할지 선택하여 성능을 높이고 설명 가능성을 지닌다는 특징이 있다. 이때 특징 선택은 인스턴스마다 다르게 적용되며(instance-wise feature selection), 개별 인스턴스의 고유한 특징이 선택되어 데이터의 다양한 특성을 반영할 수 있다. TabNet 의 특징으로 unsupervised pre-training 을 지원하며 Encoder-Decoder 를 거쳐서 예측하는 구조로 결측값들이 포함되어도 전처리 없이 성능을 크게 향상시킬 수 있다는 점이 있다[19].

TabNet 의 학습 구조는 그림 2-8 과 같이 이루어져 있다. N 번의 decision step 으로부터 Sequential attention mechanism 으로 데이터를 학습한다. 이 때 각각의 Step 이라는 단위에서 변수 선택 과정이 이루어지는데, 추출된 유용한 특징은 Feature Transformer 를 통해 데이터에 대한 인코딩을 수행한다. 이어서 Attentive transformer 를 통해서 중요한 변수(feature)을 선택하고, 다음 Decision Step 에서 학습할 변수 공간을 제한한다. Step 간에는 학습 정보를 다음 Step 으로 전달하고 이를 기반으로 피드백을 제시하면서 학습을 진행한다. 각 Step 사이의 활성화 함수는 기본적으로 ReLu 함수가 사용된다.

2.3.3.1. Feature Transformer

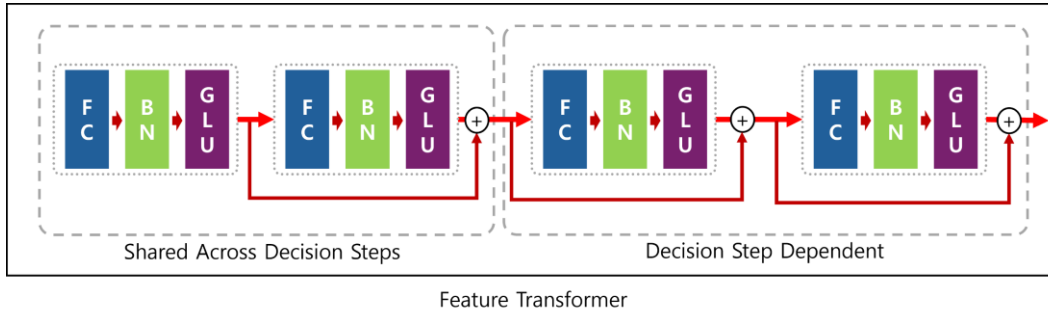


그림 2- 9. TabNet 의 Feature Transformer

Feature Transformer 는 TabNet 아키텍처의 핵심 요소로, 각 Step 에서 들어온 입력 데이터를 인코딩하여 다양한 방식으로 표현하여 복잡한 데이터 패턴도 효과적으로 학습할 수 있다. Feature Transformer 는 Shared Across decision steps 와 Decision step dependent 라는 블록으로 구성된다. 각 블록은 하이퍼 파라미터로서 설정이 가능하며 특징은 아래와 같이 나눌 수 있다.

- **Shared Across Decision Steps:** Decision Step 에서 공유되는 파라미터를 가진 층으로, 공통적인 특성을 인코딩한다. 블록을 공유함으로써 각 Decision Step 간에 일관성 있는 학습이 가능하다
- **Decision Step Dependent:** 각 Decision Step 마다 독립적으로 작용하며, 해당 Step 에서 특정되는 표현을 학습한다. 이를 통해 각 단계의 새로운 정보를 학습할 수 있다.

Feature Transformer 에서 각 Fully Connected Layer 를 거친 뒤 GLU(Gated Linear Units)[20]가 사용되는데, 이는 선형 변환 및 게이트 메커니즘을 통해 필요하지 않은 정보의 흐름을 억제, 잡음을 줄여 학습 시에 중요하지 않은 정보가 이용되지 않도록 하여 성능을 향상시킨다. GLU는 아래 식(6)과 같이 나타낼 수 있고 W 와 V 는 가중치 행렬이며, σ 는 시그모이드 함수로 어떤 입력을 통과시킬지 제어하는 역할을 수행한다.

$$GLU(x) = (X \cdot W) \odot \sigma(X \cdot V) \quad (6)$$

마지막으로 각 층의 출력을 정규화하는 Batch Normalization 을 통해 학습의 안정성을 높이고, 과적합을 방지한다. 추가로 Feature Transformer 내부에 Residual Connections 이 포함되어 있는데 이는 입력이 각 층을 통과하면서 손실되는 정보를 보완하여, 깊은 신경망에서도 성능이 저하를 방지하고 효과적인 학습을 돕도록 설계되었다.

2.3.3.2. Attentive Transformer




그림 2- 10. TabNet 의 Attentive Transformer

Attentive Transformer 는 각 Decision Step 에서 특징 선택을 수행하는 모듈이다. 이는 Sequential Attention Mechanism 을 통해 데이터를 학습하여 단계마다 중요한 특징에 집중하고 불필요한 특징은 억제하는 역할을 한다. 이를 통해 적은 수의 특징만으로 효율적 학습이 가능하고 동시에 고차원의 데이터에서도 뛰어난 성능을 보일 수 있다. Attentive Transformer 에서는 입력 데이터에 대해 특징의 중요도를 계산하고 이를 바탕으로 Feature Mask 를 생성한다. 이 Mask 는 다음 단계에서 사용될 수 있는 가중치가 높게 부여된 특징과 무시되는 특징을 구분하는 역할을 수행한다. Attentive Transformer 에서는 활성화함수로 Sparsemax 를 사용하는데 그림 2-11 와 같이 SoftMax 함수가 (0,1)의 범위에서 모든 값의 합이 1 이 되도록 부드럽게 확률을 설정한다면, Sparsemax 의 경우 출력 값 중 일부를 0 으로 만들어 불필요한 정보는 억제하여 희소성(sparsity)을 확보한다. 반대로 필요한 정보는 1 로 만들어 중요한 정보에는 집중할 수 있도록 한다.




그림 2- 11. Sparsemax 와 SoftMax 의 비교[21]




그림 2- 12. TabNet 의 Mask 기반의 설명 가능성[10]

TabNet 모델은 생성된 Feature Mask 를 활용하여 각 입력 데이터의 특징별 중요도를 학습하여 나타낼 수 있으며, 이를 통해 TabNet 은 학습된 데이터에 대한 설명 가능성을 제공한다. Mask 기반의 설명 가능성을 활용하면 학습된 모델이 특정 예측 결과를 도출하는 데 사용된 각 특징의 기여도를 분석할 수 있다. 아래 그림 2- 12 는 TabNet 의 Feature Mask 를 전역적으로 시각화한 예시와 단계별로 시각화한 예시를 보여준다. 이러한 과정을 통해 Feature Mask 는 TabNet 의 각 학습 단계에서 선택된 특징의 가중치를 시각적으로 표현할 수 있으며, 이는 모델이 입력 데이터를 처리하고 결론을 도출하는 과정을 이해하는 데 중요한 정보를 제공한다. 이는 데이터 전처리 단계나 모델 개선 과정에서도 유용하게 활용될 수 있으며 사용자의 모델 튜닝에 직간접적으로 도움을 줄 수 있다. 결론적으로, TabNet 은 데이터와 결과 간의 관계를 명확히 이해할 수 있는 설명 가능한 인공지능 모델로, 다양한 응용 분야에서 신뢰성 높은 설명 가능한 인공지능 시스템을 구축할 수 있는 도구로서 응용이 가능하다.

3. 공작기계 설비 데이터 수집 및 분석

3.1. MCT 설비 구조 및 고장 유형

공작기계 중 하나인 MCT(Machining Center Tool)는 주로 복잡한 형상의 공작물을 정밀하게 가공하기 위해 사용되는 기계다. MCT 는 주로 스핀들에 의해 단단히 고정된 절삭 공구를 통해 공작물을 절삭 가공하는데, 설비에 따라 X, Y, Z 축으로 정밀한 이동을 통하여 가공을 수행한다. 이러한 정밀 가공을 통해 특정한 형상물을 생산할 수 있는 장점을 지니고 있지만, 모터 제어 및 절삭 과정에서 여러 기계 부품을 사용하면서 다양한 결함이 발생할 수 있다. 실험에서 선정된 결함 유형은 MCT 설비에서 자주 발생하는 결함 중 일부이며 각각의 발생 원인과 그로 인해 발생하는 문제점은 다음과 같다.

- **베어링 결함**
 - 발생 원인: 부하로 인한 마모, 윤활 부족 및 윤활유 오염, 축 정렬 불량 등으로 인한 하중 부담
 - 발생하는 문제: 스핀들 진동 증가로 가공 정밀도 저하, 베어링 파손 시 스핀들 또는 축 등의 기계적 손상, 소음 증가
- **기어 결함**
 - 발생 원인: 부하로 인한 기어 이빨 마모, 윤활 부족, 기계의 정렬 불량
 - 발생하는 문제: 동력 손실로 인한 가공 불량, 설비 가동 중단 초래, 연쇄 손상 위험 발생 가능성
- **공구 결함**
 - 발생 원인: 가공 속도 및 절삭 깊이 설정, 절삭 재료 선정 오류
 - 발생하는 문제: 공작물의 스크래치 및 형상 오류 발생, 불량품으로 생산성 저하, 공구 파손으로 인한 위험


3.2. 테스트 베드 구조 및 실험 설정

공작 기계 설비의 결함 분류를 목적으로 제안되는 신호처리와 인공지능에 사용되는 데이터 셋을 구축하기 위해서 MCT 테스트 베드를 활용하여 데이터를 취득한다. 테스트 베드는 모터를 통해 X, Y 축 2 가지 방향으로 이동하는 동안의 절삭 공정을 재현함과 동시에 3 가지의 기계적 결함을 모사 가능하도록 설계되었다. 테스트 베드의 전체적인 형태는 그림 3-1 의 (a)와 같다. 진동 센서는 (b)과 같이 100mV/G 센서를 모터 부근에 500mV/g 센서를 스핀들 부근에 설치했다. 모터 쪽에 100mV/g 센서를 통해 절삭 가공 시 발생하는 큰 진동을 효과적으로 감지하고, 기어 매쉬 진동(GMF)등의 높은 주파수 성분 등의 데이터를 수집하고자 한다. 스핀들 부분에는 500mV/g 의 진동 센서를 설치하여 가공 절삭 동안의 발생하는 진동과 공구 마모로

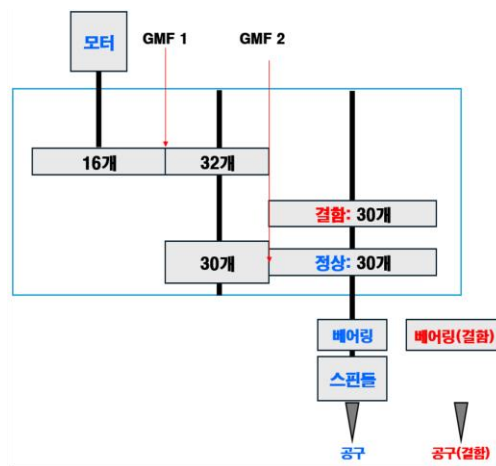
인한 결함의 미세한 진동 신호에 대한 데이터를 수집하고자 한다. 이와 같이 설비의 요소별 위치에 적합한 센서를 선정하여 데이터를 취득함으로써 발생하는 결함 성 진동 신호를 효과적으로 진단할 수 있을 것으로 기대한다. 또한 실험에서 모사한 결함으로는 베어링 결함, 기어 결함, 공구 결함을 모사하여 구성하였다. 그림 3-2 는 실험에서 사용된 각 결함 요소들의 실물 사진이며 결함 모사 방식은 그림 아래에 정리하였다.



(a) 테스트 베드의 실물 사진



(b) 진동 센서 설치 위치



(c) 테스트 베드 구성요소 도식화


그림 3-1. 실험에 사용된 MCT 테스트베드



(a) 베어링 결함



(b) 기어 결함



(c) 정상 공구



(d) 결함 공구

그림 3- 2. 실험에 사용된 결함 요소

- **베어링 결함:** 베어링 외륜에 약 3mm 의 절삭하여 결함 상태를 모사함
- **기어 결함:** 기어 이빨 하나를 파손시켜 결함 상태를 모사함
- **공구 결함:** 공구 날을 인위적으로 마모해 절삭 성능이 저하된 상태를 모사함

3.3. 데이터 수집

데이터 수집은 3 가지의 다른 절삭 속도 조건 아래에서 정상 상태와 각 결합 상태 (베어링 결합, 기어 결합, 공구 결합)를 설정한 뒤 절삭 가공 동안 진동 데이터를 취득한다. 실험 과정은 알루미늄 가공물의 면을 X 축의 방향으로 0.3mm/s 속도로 절삭하면서 이동하는 동안 1 초 간격으로 진동 데이터를 저장하는 방식으로 진행된다. 이때 공구날은 공통적으로 2 날의 직경 2mm 공구가 사용되며, 사용된 피 절삭물은 그림 3-3 과 같은 알루미늄 재료의 피 절삭물을 사용한다. 총 실험의 시나리오는 표 3-1 와 같으며 피 절삭물에서 절삭이 시작되는 Y 축 위치에 따라 실험의 아이디를 부여한다.




그림 3- 3. 실험에서 사용된 피 절삭물과 가공 형태

Moter RPM	Spindle RPM	절삭 공구의 회전 주파수	시행 횟수	실험 내용
1440	720	12 hz	3 회	X 축 방향으로 1 회 가공
1320	660	11 hz	3 회	X 축 방향으로 1 회 가공
1200	600	10 hz	3 회	X 축 방향으로 1 회 가공

표 3- 1. 실험 시나리오

3.4. 수집 신호 분석

수집된 데이터는 진동 데이터로 모터 쪽의 100mV/g 진동 센서와 스피들 쪽의 500mV/g 진동 센서로 구분되어 초 단위로 저장된다. 이때 초당 샘플 수는 25600 개로 설정하였고 신호 분석 시 노이즈 성 신호를 최소화하고 결함 주파수를 확실하게 구분하기 위해 1 초로 수집된 신호를 10 초로 이어서 활용한다. 분석에서는 결함 별 진동 데이터의 시간 파형, 가속도 주파수 스펙트럼, 속도 스펙트럼, 포락 스펙트럼을 구분하여 나타낸다. 또한 각 그림에서는 1X 성분부터 10X 성분의 배수 성분과 그 값을 시각화하여 나타내고 설비에서 발생하는 기어 매시 주파수(GMF)도 함께 표시한다. 가속도 스펙트럼에서는 회전 주파수 및 구성 성분 간의 마찰로 인해 발생하는 취득된 원시 신호 성분에 대해 분석하고, 포락 스펙트럼에서는 공구 결함이나 베어링 결함으로 인해 발생하는 충격성 신호 등의 패턴을 보이는지에 대해서 분석한다. 또한 속도 스펙트럼을 통해 에너지의 분포를 확인한다. 각 분석에 사용된 데이터는 모터 RPM 1320 에서 취득된 데이터를 활용하며, 사용된 각 센서의 주파수 범위와 감도는 그림 3-4 와 같다. 100mV/g 의 진동 센서는 중저주파 대역에서 안정적인 응답을 보이며, 500mV/g 의 센서는 저주파 대역에서 높은 민감도, 고주파 대역에서는 감도 편차가 증가하여 불안정성을 보인다.

모터에 설치된 100mV/g 의 진동 센서

- Frequency Range ($\pm 5\%$): 35 to 360000 cpm, 0.58 to 6000 Hz
- Frequency Range ($\pm 10\%$): 25 to 600000 cpm, 0.42 to 10000 Hz
- Resonant Frequency: 30 kHz Nom.

스피들에 설치된 500mV/g 의 진동 센서

- Frequency Range ($\pm 5\%$): 60 ~ 540,000 cpm, 1 to 9000 Hz
- Frequency Range ($\pm 10\%$): 30 ~ 840,000 cpm, 0.5 to 14000Hz
- Resonant Frequency: 25 kHz Nom.




그림 3- 4. 센서 별 주파수 감도 편차 [22]

3.4.1. 정상 신호 분석

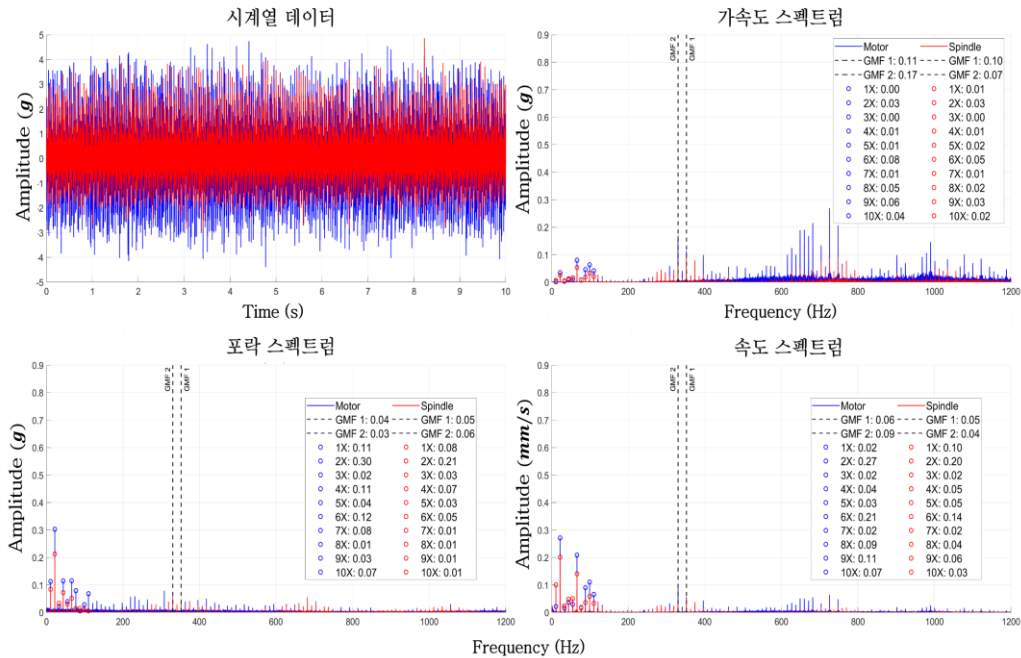


그림 3- 5. 정상 신호의 시계열 및 스펙트럼 분석

정상 신호의 경우 시간 영역의 경우 진폭이 $-4g$ 에서 $+4g$ 값의 범위 내에서 변동한다. 또한 뚜렷한 이상 신호 없이 주기적인 패턴이 일정하게 나타나며 각 센서의 데이터도 크게 구분되지 않는 특징을 보인다. 주파수 영역에서는 절삭 공정과 절삭 공구와 관련된 11Hz , 22Hz 의 연속적인 배수 성분이 관측된다. 포락 스펙트럼에서는 22Hz 주파수 성분이 주변 피크 보다 높게 발생하는 이유는 절삭 공구가 2 날 공구이기 때문에 1 회전의 절삭을 하는 경우 각 날이 절삭 표면당 한번씩 접촉하며 2 회의 진동을 유발한다. 이를 Tool Pass Frequency(TPF) 라고 하며 절삭 공정의 신호 분석에서 중요한 요소이다. 일반적으로 정상적인 공구인 경우 TPF 가 지배적으로 나타나며 추가적인 배수 성분들이 일부 관측된다. 속도 스펙트럼에서도 2X 성분이 나타났으며 추가로 6X 성분의 데이터도 주변 피크에 비해서 높게 발생하는 현상을 보였다.

3.4.2. 베어링 결함 신호 분석

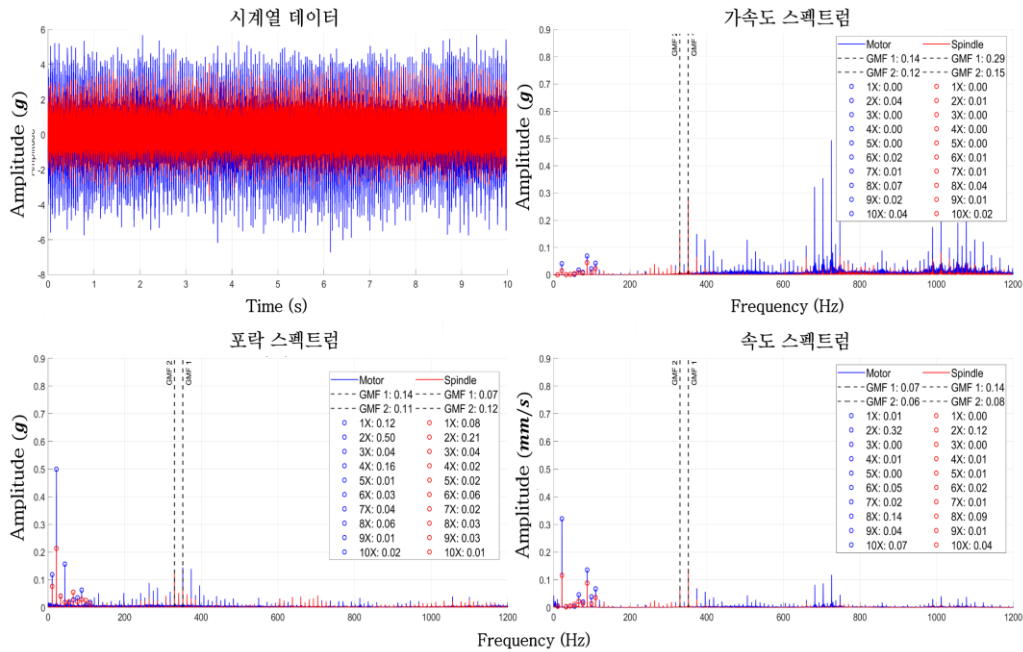


그림 3- 6. 베어링 결함 신호의 시계열 및 스펙트럼 분석

베어링 결함은 시간 영역에서 100mV/g(모터) 센서에서는 진폭 변동이 증가, 동시에 500mV/g 센서(스핀들) 에서도 정상 신호보다 불규칙하고 비주기적 충격 신호들이 신호에 다수 관측되었다. 베어링 결함의 경우 외륜 결함을 인위적으로 3mm 크기로 발생시켰기 때문에 가속도 스펙트럼 내에서 비교적 고주파 영역인 700Hz 와 1000Hz 부근의 성분들이 크게 검출되었다. 또한 몇몇 배수 성분들이 매우 낮은 값으로 검출되었다. 반면에 포락 분석에서는 변조된 신호들이 사라지면서 2X 신호가 높게 발생하였고, 배수 성분의 신호들도 검출되었다. 특히 100mV/g(모터) 신호가 크게 증가하였다. 속도 스펙트럼에서도 2X 신호가 크게 나타났으며 동시에 8X 성분이 증가하는 경향이 있었다. 또한 몇몇 배수 성분이 매우 낮은 값으로 검출되는 동일한 특징도 있었다. 외륜 결함의 경우 구름요소가 결함부를 지나갈 때 충격을 발생시키는데, 이에 따라 절삭과 관련된 TPF 성분이 증가된 것으로 추측된다.

3.4.3. 기어 결합 신호 분석

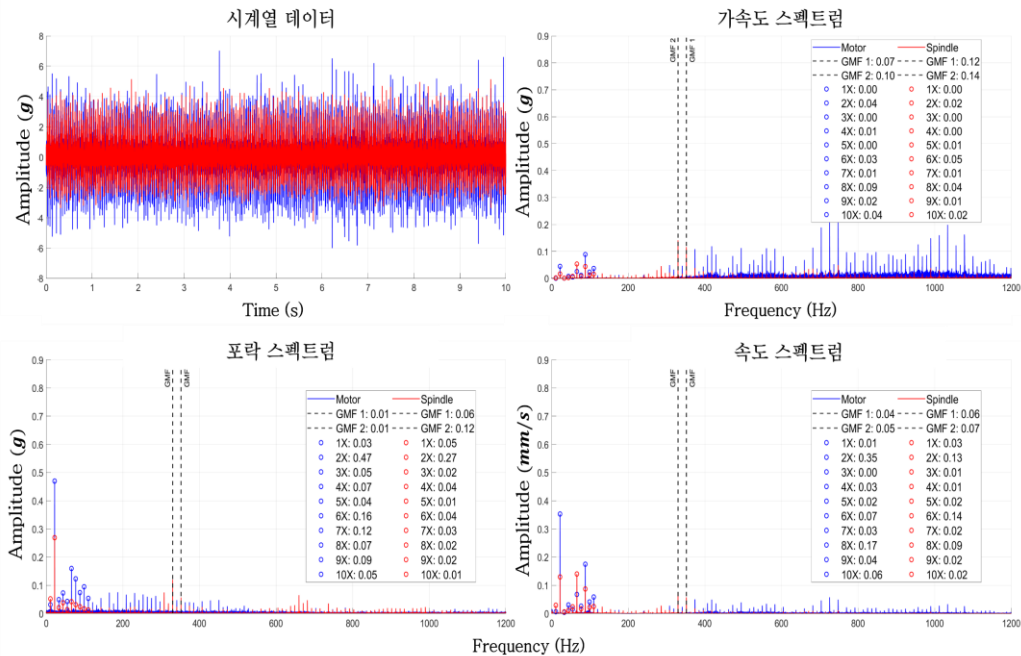


그림 3- 7. 기어 결합 신호의 시계열 및 스펙트럼 분석

기어 결합 또한 시간 영역에서 진폭 변동이 정상 신호에 비해 증가하여 $-6g$ 에서 $+6g$ 값의 범위 내에서 불규칙한 진폭 변화가 각 센서에서 관측된다. 이는 기어 결합으로 인한 충격 발생에 의해 비정상적인 진동이 발생하였기 때문이다. 기어 결합 또한 시간 영역에서 진폭 변동이 정상 신호에 비해 증가하였으며 불규칙한 진폭 변화가 각 센서에서 관측된다. 가속도 스펙트럼에서는 500Hz 에서 1500Hz 에 이르는 넓은 주파수 대역에서 여러 피크 신호들이 관찰되었는데 이러한 피크 신호들은 기어 이 파손으로 인해 절삭 공정 중에 발생하는 충격성 신호 발생에 기인한 것으로 판단된다. 이는 결합 상태에서 기어 맞물림 주파수(GMF)와 그 고조파 성분들이 동적으로 상호작용하며 발생한 특징으로 넓은 영역에 산발적으로 나타난 것으로 보인다. 속도 스펙트럼에서는 저주파의 특징들이 강조되게 나타났으며, 포락 스펙트럼에서는 변조된 신호들이 제거되고 기어 결합과 직접적으로 연관된 주요 주파수 성분들이 명확하게 구분된 것을 확인할 수 있다. 특히, GMF 와 그 측대역 주파수 성분들이 정상 신호에 비해 강조되었다. 이에 따라 기어 결합 분석에서도 베어링 결함과 마찬가지로 가속도 스펙트럼 및 포락 분석이 결합 신호를 효과적으로 추출하고, 결합의 동적 영향을 명확히 분석하는 데 유용한 도구임을 확인할 수 있다.

3.4.4. 공구 결함 신호 분석

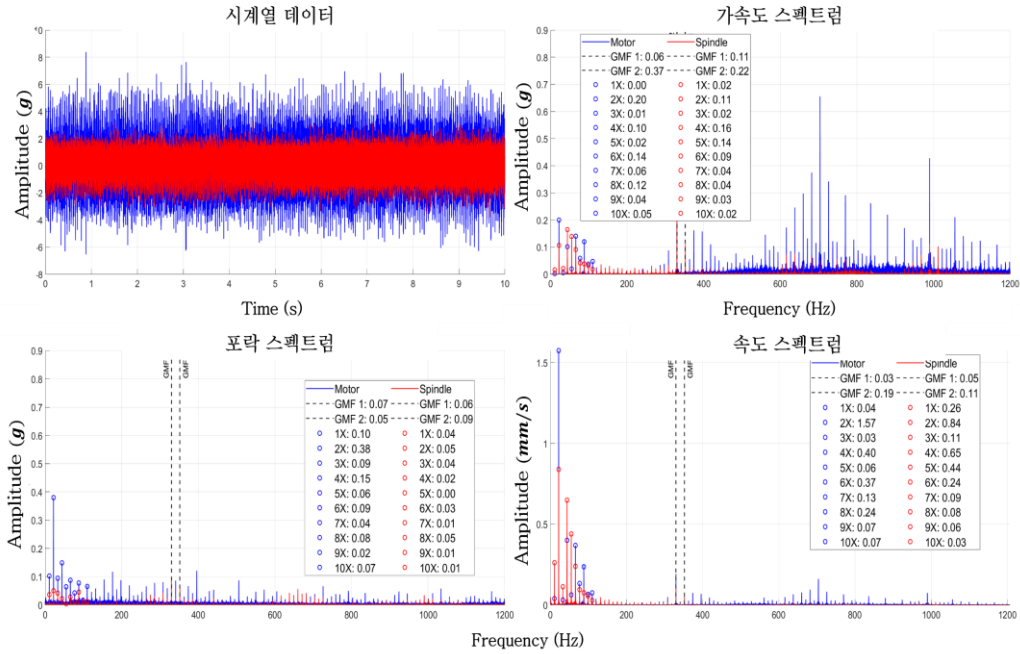


그림 3-8. 공구 결함 신호의 시계열 및 스펙트럼 분석 1

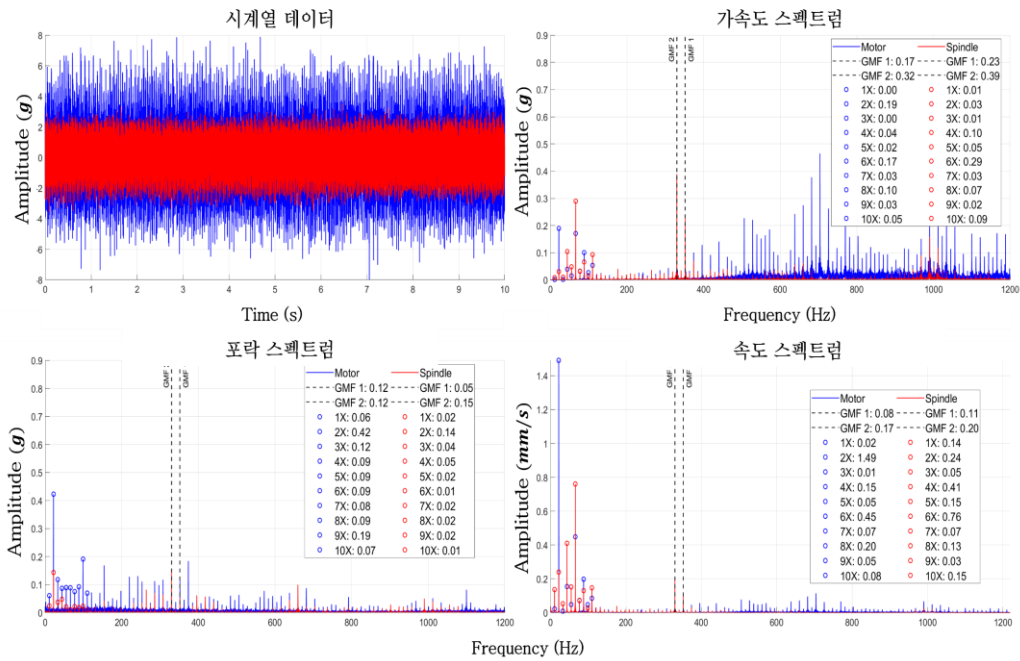


그림 3-9. 공구 결함 신호의 시계열 및 스펙트럼 분석 2

공구 결합의 경우 모터의 시간 파형이 스핀들의 진폭보다 많이 증가한 것을 확인할 수 있으며 두 신호에서 불규칙한 패턴을 보인다. 이는 공구 마모로 인해 비주기적인 충격 신호가 모터의 진동에 영향을 주었음을 의미한다. 스핀들 진동은 모터 진동보다 비교적 작은 크기의 진동이 관측되었다. 실험을 통해서 공통으로 발견한 특징은 스핀들에 부착된 500mV/g 센서에서 포락 스펙트럼 등의 분석 시 TPF(2X)의 피크가 감소하는 경향이 있다는 사실이었다. 이는 칼날로 절삭물을 깎아내던 공정이 마모된 날로 인해 뭉개지듯이 거칠게 절삭되면서 다른 주파수 성분들로 에너지가 분산되기 때문으로 해석된다. 따라서 예리하게 절삭하지 못하여 피절삭물을 짓이겨내듯이 가공하기 때문에 불규칙한 진동이 발생하여 실험마다 다른 주파수 스펙트럼 양상을 보이는 것으로 추측된다. 한편, 모터 측의 100 mV/g 센서로 측정된 속도 스펙트럼에서는 TPF가 크게 증가하는 경향을 보였다. 이는 절삭 공구의 마모로 인해 절삭이 원활하지 않아 발생한 부하 에너지가 스핀들을 통해 모터로 전달된 결과로 해석된다.

4. 제안하는 신호처리 방법 및 데이터 구축

4.1. 회전 성분 기반의 구간 생성 및 특징 추출 알고리즘

일반적으로 주파수 데이터를 분석할 때 최대 주파수와 주파수 간격에 따라 특징의 개수가 결정된다. 주파수 특징 수의 증가는 진단 정밀도를 높일 수 있지만, 동시에 연산 및 시스템의 부하를 유발하고 잡음에 민감하게 반응할 수 있다. 특히 딥러닝에서는 차원의 저주와 같은 문제를 초래할 수 있다. 고장 진단에서는 동일한 설비에서 수집된 신호일지라도 주변 환경과 운전 상태 등에 따라 설비의 진동 신호가 다른 양상으로 나타날 수 있다. 따라서 기존에 수집된 데이터로 학습된 알고리즘이 동일한 성능을 보이는지에 대한 재현성 입증에 어려움이 있다. 많은 주파수 특징을 학습에 사용한 모델인 경우 학습 데이터 환경이 지닌 고유한 특징까지 학습하여 일반적인 고장 패턴과 무관한 신호에 민감하게 반응할 가능성이 높기 때문이다. 이러한 점이 학습 시 커널을 활용하여 특징을 추출하고, 특징 맵을 축소하면서 과적합을 방지하는 합성곱 신경망(CNN)이 고장 진단 분야와 주파수 도메인에서 효과적으로 활용되는 이유 중 하나이다.

공작기계 설비의 경우 결합 성 신호의 주파수는 절삭 및 회전 그리고 기계요소와 관련된 특정 주파수 대역에서 명확한 피크 성 신호로 주로 나타난다. 이는 회전속도에 따라 신호의 위치가 달라지며 주로 회전 성분(1X, 2X 등)에 관련된다. 고주파 영역에서의 소음 및 마찰성 신호 또한 중요하지만 이를 세밀하게 분석한다면 차원의 저주와 같은 문제가 발생할 가능성이 크다. 따라서 회전 성분이 크게 담긴 저주파 신호와 소음 및 마찰 신호인 고주파 신호를 균형 있게 분석하는 전략이 필요하다. 이를 위해 로그 스케일링 기반의 회전 성분 단위의 간격을 통한 특징값 추출 형식의 신호처리 알고리즘을 제안한다. 제안하는 신호처리 방식의 프로세스 다이어그램은 아래 그림 4-1 과 같다.

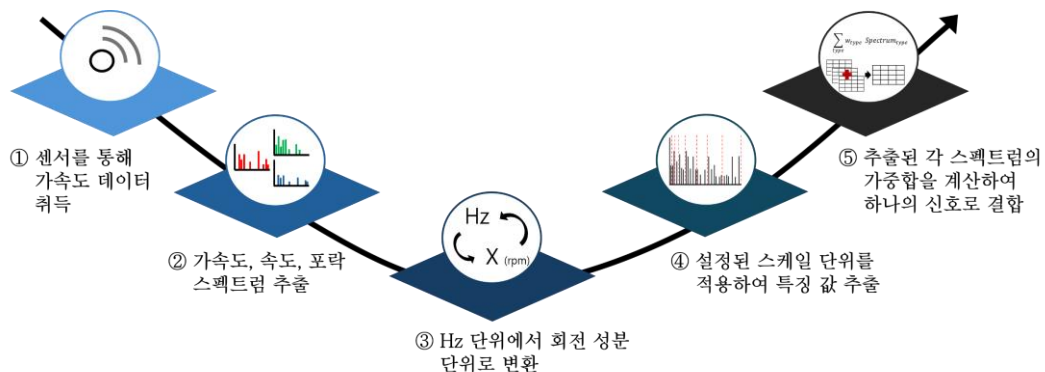


그림 4- 1. 프로세스 다이어그램

1 번 과정을 통해 수집된 가속도계 센서 데이터는 다이어그램의 2 번 과정에서 적분과 힐버트 변환 등의 수식을 사용하여 속도와 포락 스펙트럼으로 변환된다. 이어서 3 번 과정에서는 각각의 스펙트럼을 회전 성분의 X 단위로 변환한다. 이때 회전 수(RPM)가 정의된다면 기본 회전 주파수인 1X 성분을 계산할 수 있는데 이는 아래 식 7 과 같다. 이 때 구한 f_{base} 를 통해 주파수 f 가 주어졌을 때, 이를 X 단위로 변환할 수 있으며 이를 일반화하여 정리할 수 있다.

$$f_{base} = \frac{RPM}{60} \text{ Hz} \quad (7)$$

$$X(f) = \frac{f}{f_{base}} = \frac{60 * f}{RPM} \quad \text{Let } f : R \rightarrow R$$

다이어그램의 4 번 과정의 경우 특정 주파수 대역의 중요성을 반영하기 위한 처리 기법으로 저주파와 고주파의 특정 추출을 위한 구간을 입력된 인자를 통해 생성한다. 이는 로그 스케일을 활용하여 회전기기의 저주파성 배수 성분 신호 특성은 최대한 보존하면서 고주파성의 신호 특성은 압축시키면서 추출하여 상대적으로 중요도가 낮아지도록 한다. 주파수 구간의 생성은 제안된 수식 8 에 따라 생성된다. 제안된 로그 스케일 기반의 구간 설정 방식은 고정된 구간 간격을 사용하는 방식이 아닌 구간의 수와 최대/최소 회전 성분 등의 인자에 따라 일관된 주파수 구간을 생성한다. 이는 다양한 환경에서도 동일한 기준으로 분석 및 데이터를 설계하는 것을 가능하게 한다. 또한, 특정 인자를 공유한다면 데이터 압축과 함께 다른 현장 및 설비 간의 데이터 표준화가 가능하므로, 데이터의 활용도를 극대화하고 결합 분석이나 인공지능의 학습 데이터에서 유용하게 활용될 수 있을 것이라 기대한다.

$$x_i = \exp\left(\log(x_{min}) + i \cdot \frac{\log(x_{max}) - \log(x_{min})}{N - 1}\right), \quad i = 0, 1, \dots, N - 1 \quad (8)$$

$$IF |x_{i+1} - x_i| < d_{min}, \quad x_{i+1} = x_i + d_{min}$$

x_{min} : 분석할 회전 성분의 최솟값

x_{max} : 분석할 회전 성분의 최댓값

N : 스케일링 구간의 갯수

x_i : 로그 스케일에 따라 구분된 각 주파수 구간의 값

d_{min} : 구간 중복 방지를 위해서 각 값의 최소 차이 설정

그림 4-2에서는 진동 데이터를 주파수 영역으로 변환하고 회전 성분을 축으로 표시한 뒤, 회전 성분의 구간을 생성하고 각 구간에 대해서 특징 값을 추출하는 예시이다. 그림에서는 Peak 특징값을 추출하는 예시를 보여주며, 빨간 점선으로 각 구간을 구분하고 해당 구간에 Peak 특징(붉은색 점)이 추출되는 것을 확인할 수 있다. 이러한 과정을 이전 과정에서 변환된 모든 가속도, 속도, 포락 스펙트럼에서 동일하게 적용하여 아래 표 4-1과 같은 데이터 셋을 생성한다.

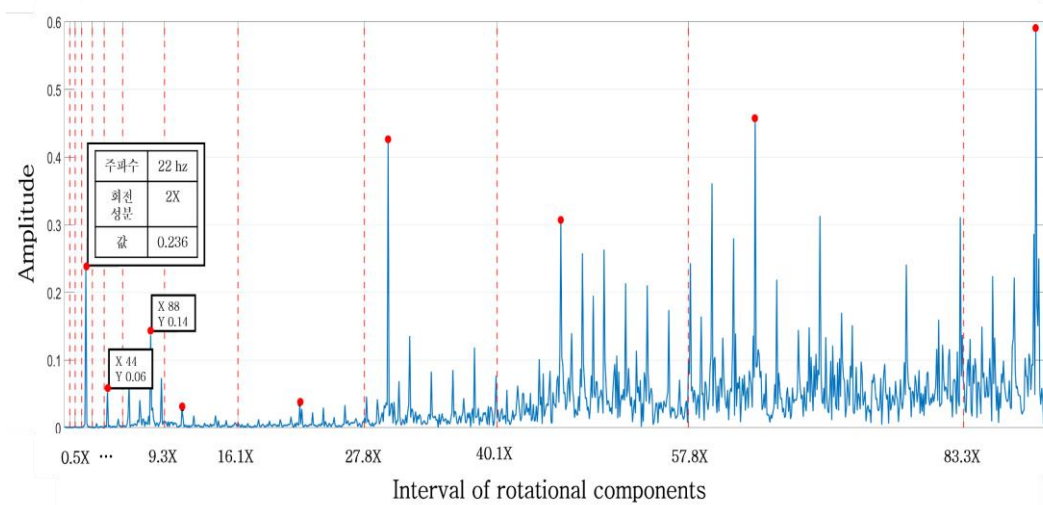


그림 4-2. 데이터 추출 방식

Filename	Channel	Type	Label	0.00~ 0.50	0.50~ 0.60	0.60~ 0.80	0.80~ 1.00	1.00~ 1.20
MCT_VIB	Moter	Acc	BF	0.002	0.001	0.001	0.004	0.002
MCT_VIB	Moter	Vel	BF	0	0.113	0.120	0.211	0.117
MCT_VIB	Moter	Env	BF	0.012	0.022	0.032	0.093	0.031
MCT_VIB	Chuck	Acc	BF	0.007	0.003	0.005	0.004	0.006
MCT_VIB	Chuck	Vel	BF	0	0.107	0.142	0.094	0.091
MCT_VIB	Chuck	Env	BF	0.029	0.015	0.026	0.285	0.025
⋮								

표 4-1. 구간별 Peak 추출 후 데이터 셋 형식

다이어그램의 5 번 과정에서는 추출된 각각의 스펙트럼(Acceleration, Velocity, Envelope)의 구간별 특징 데이터에 대해 설비의 특성과 결함 진단의 중요도를 반영한 가중치를 부여한 후, 이를 하나의 채널로 압축하는 단계를 수행한다. 이 과정은 각 스펙트럼의 특성을 고려하여, 진단하고자 하는 설비나 결함 유형에 맞춰 중요한 정보를 강조하고, 상대적으로 덜 중요한 정보를 축소하여 최종 진단 효율을 극대화하는 것을 목적으로 한다. 이때, 수식 7 과 같이 모든 가중치의 합이 1 이 되도록 정규화하여 스펙트럼 간의 균형을 유지한 뒤 단일 채널로 압축한다. 이를 통해 데이터의 크기를 줄이고 입력 공간의 차원을 감소시켜 학습 알고리즘이 다차원 데이터를 보다 단순화된 형태로 효과적으로 처리할 수 있도록 한다. 압축된 데이터는 중요한 특징을 크게 포함하여 학습 모델이 불필요한 정보에는 영향을 덜 받게 하여 학습 과정의 효율성을 향상하는 것을 목적으로 설계되었다. 아래 표 4-2 는 각 스펙트럼이 가중합 과정을 거친 뒤 최종 압축 및 변환 완료된 데이터 셋의 형태이다.

$$X_{weighted} = w_{Acc} \cdot X_{Acc} + w_{Vel} \cdot X_{Vel} + w_{Env} \cdot X_{Env}$$

group by, File and Channel (7)

Filename	Channel	Type	Label	0.00~ 0.50	0.50~ 0.60	0.60~ 0.80	0.80~ 1.00	1.00~ 1.20
MCT_VIB	Moter	W	BF	0.006	0.076	0.061	0.121	0.068
MCT_VIB	Chuck	W	BF	0.005	0.097	0.052	0.137	0.061
								...

⋮
표 4- 2. 최종 결과 데이터 셋 형식

4.2. 제안된 신호처리 적용 유무의 데이터 비교

4.2.1 1Hz 단위의 가속도 주파수 데이터

1Hz 단위의 가속도 주파수 데이터셋은 신호처리가 적용되지 않은 가속도계 센서를 통해 수집된 데이터를 활용한다. 이 때 최대주파수는 7000 Hz 까지 추출하여 저장한다. 이러한 데이터 셋은 진동 분석 및 인공지능 알고리즘을 통한 결함 분류에 자주 활용되는 데이터 형태로, 대용량의 데이터지만 처리가 간단하고 신호의 무결성을 해치지 않기 때문에 미세한 변화까지 탐지가 가능하다. 하지만 이로 인해 저장 및 처리에 대한 비용이 크고 인공지능의 학습 데이터로 활용하는 경우 과적합되거나 노이즈 성 신호를 학습하여 일반화 능력이 감소할 가능성이 존재한다. 아래 그림 4-3 은 1320RPM 에서 수집된 각 결함 및 정상 데이터를 1Hz 단위로 출력한 형태이다. 100mV/g 모터 센서에서는 저주파 대역의 신호가 상대적으로 강하게 관측되며, 500mV/g 의 스피들 센서에서는 저주파를 포함해 전체적으로 신호의 특징이 결함 별로 차이를 보이는 것이 확인된다. 이러한 과정으로 모든 데이터 셋에 대해 같은 처리를 적용해 1Hz 단위의 해상도를 가지는 최대 주파수 6000Hz 의 데이터 셋을 각 실험별로 구축하였다.

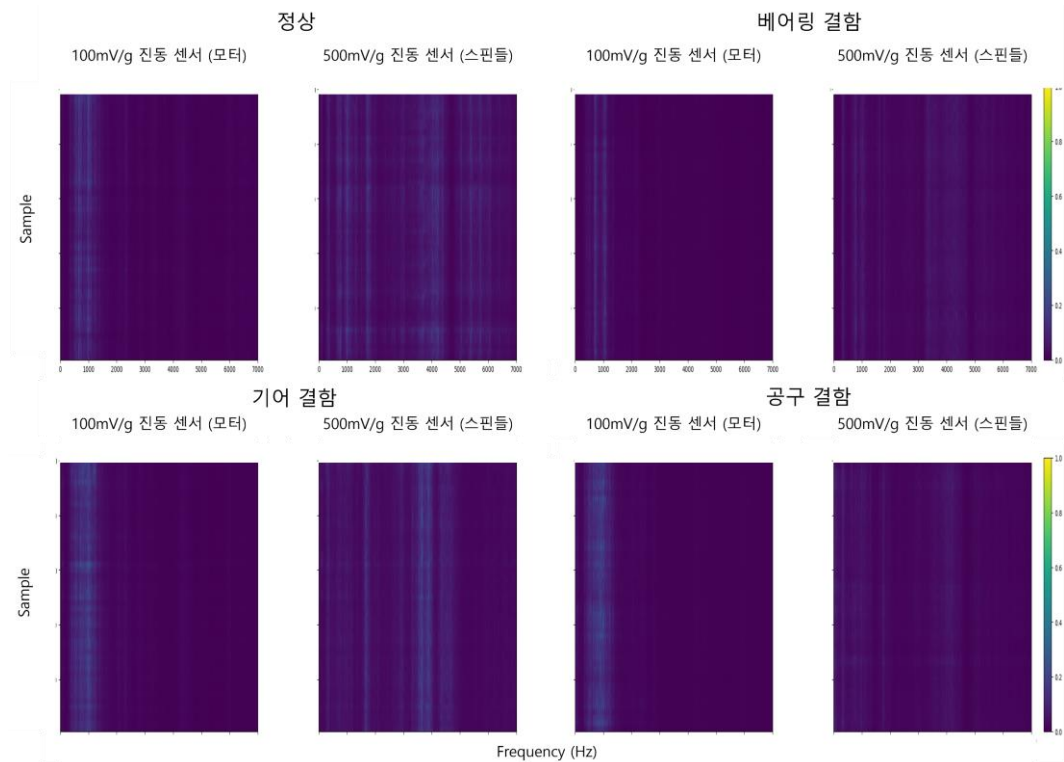


그림 4-3. 결함 및 센서 별 1Hz 단위의 가속도 주파수 데이터 셋

4.2.2. 신호처리를 통해 압축 및 변환된 주파수 데이터

다음은 제안된 신호처리 기법으로 변환된 데이터 셋으로 가속도 주파수 데이터를 압축 및 변형한 형태이다. 아래 그림의 적용된 신호처리 인자로는 회전 성분의 최대 최소인 x_{min} 와 x_{max} 는 이전의 데이터셋과 비슷한 대역을 지닌 0.5 와 600 으로 설정하였다. 또한 구간의 개수인 N 은 30 을 설정하였다. 각 스펙트럼의 가중치는 동일하게 나누었고, 학습 시에는 신호 분석 결과를 토대로 신호처리 인자를 설정할 계획이다.




그림 4- 4. 신호처리로 변환된 정상 신호의 예시

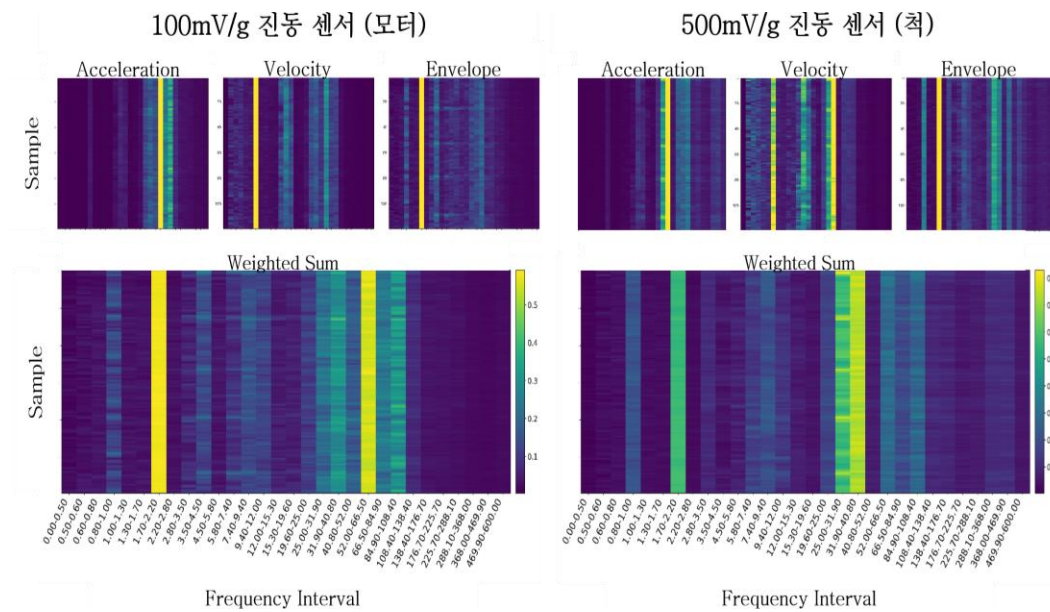


그림 4- 5. 신호처리로 변환된 베어링 결함 신호의 예시




그림 4- 6. 신호처리로 변환된 기어 결함 신호의 예시

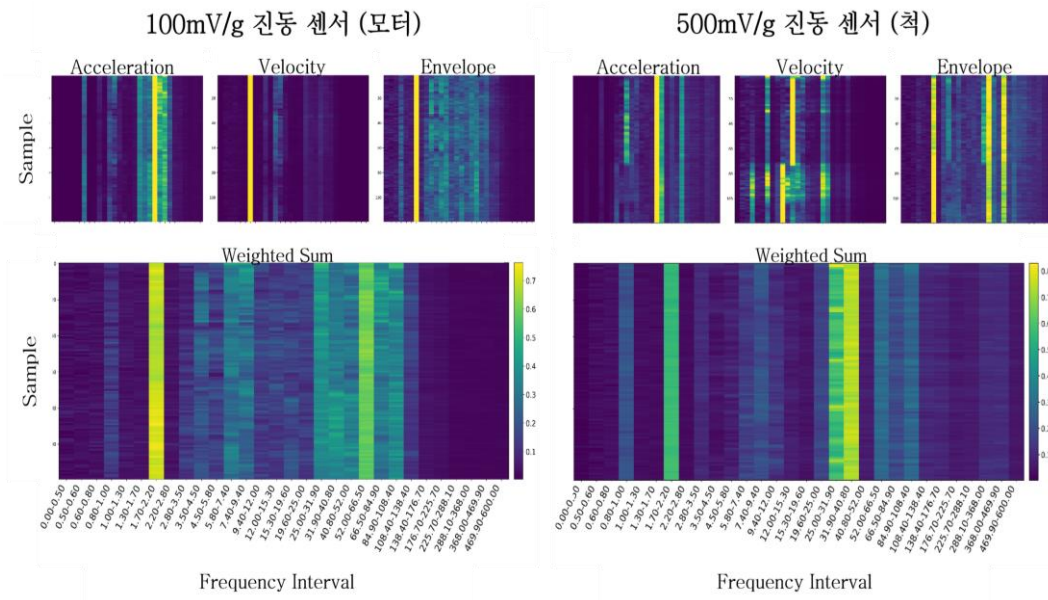


그림 4- 7. 신호처리로 변환된 공구 결함 신호의 예시

4.2.3. 신호처리에 따른 용량 및 특징 비교

그림 4-8 은 제안된 신호처리 방식을 적용 유무와, 설정된 파라미터 N (구간의 개수) 값에 따라 데이터 구성과 해상도가 어떻게 달라지는지를 보인다. 이를 통해 동일한 가속도 신호에서 N 값을 조정함으로써 데이터 압축 및 특징 추출 효과를 비교할 수 있다. 이어지는 표 4-3 은 N 값에 따른 데이터 압축 효과를 수치상으로 나타낸다. 제안된 신호처리 방식은 데이터 포맷을 일관되게 관리할 수 있는 장점을 제공한다. 신호처리에 사용되는 수식의 인자를 공유함으로써, 서로 다른 설비와 환경에서 수집된 데이터를 동일한 형식으로 변환할 수 있다. 이는 주파수 데이터를 효과적으로 압축하고 관리하는 데 도움을 주며, 다양한 데이터 소스를 통합하거나 비교하는 과정을 용이하게 한다. 이러한 통합된 데이터 구조는 인공지능 모델의 학습과 예측 성능을 극대화할 수 있는 기반을 마련한다. 또한, 제안된 방식은 과 적합 위험을 감소시키고 학습 비용을 줄이는 데 기여한다. 신호의 특징 수를 제한함으로써, 인공지능 모델이 중요한 정보에 집중할 수 있도록 하고, 불필요한 계산을 줄여 학습 효율을 높인다. 이는 특히 대규모 데이터셋에서 적은 자원으로도 효과적인 학습을 가능하게 하며, 인공지능 기반의 설비 진단과 예측 유지보수 시스템의 성능을 개선할 수 있다. 결론적으로, 제안된 신호처리 방식은 데이터의 효율적 압축과 관리, 인공지능 활용도를 크게 향상하는 효과적인 방법으로 진동 데이터를 체계적으로 활용할 수 있도록 한다.

100mV/g 진동 센서 (모터)에서 취득된 기어 결함 신호

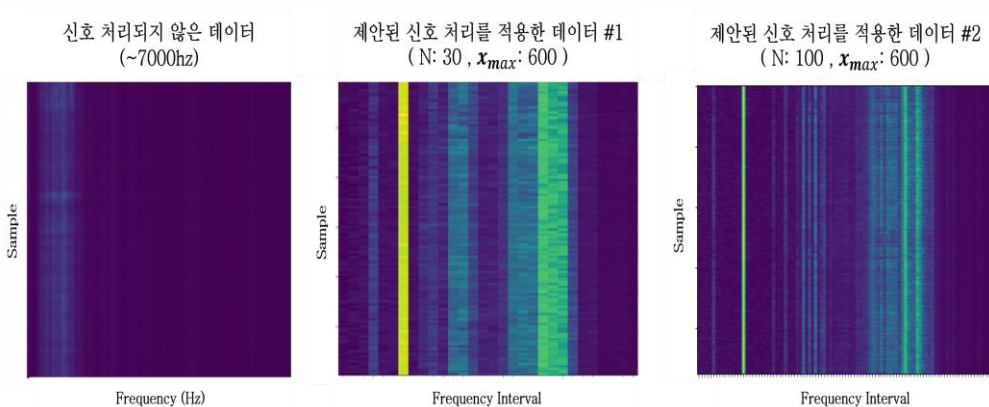


그림 4- 8. 신호 처리 적용 전후의 용량 비교

데이터 셋	구간(특징) 개수	용량
신호 처리되지 않은 데이터	7000	약 73.4MB
제안된 신호 처리를 적용한 데이터 #1	30	약 1.08MB
제안된 신호 처리를 적용한 데이터 #2	100	약 3.28MB
제안된 신호 처리를 적용한 데이터 #3	200	약 6.58MB

표 4- 3. 신호 처리 적용 전후의 용량 비교

4.3. 데이터 증강 기법 적용

최종 전처리를 마친 후, 데이터의 일반화 능력을 향상하기 위해 랜덤 스케일링 기반 데이터 증강 기법을 제안한다. 진동 데이터를 신호처리를 통해 변환하고 가중합을 나타낸 결과, 결합별로 주파수 대역별 진폭 값의 범위가 여전히 뚜렷하게 구분되는 특성이 존재했다. 이는 TabNet 과 같은 딥러닝 알고리즘이 데이터의 특정 패턴을 학습하기보다는 주파수 대역별 값의 차이에만 의존되게 판단하면서, 일반화 성능이 저하될 가능성이 있다. 따라서 이러한 문제를 해결하고자 각 데이터에 일정 범위에서 값을 곱하여 주파수 대역별 진폭 값의 분포를 다양화하였다. 이러한 방식을 통해 회전 성분 간의 특징적 분포는 유지하면서도, 딥러닝 모델이 성분의 값에만 의존하지 않고 회전 성분 구간 간의 패턴을 인식하여 학습하는 것을 목적으로 한다. 특히, 이러한 증강은 모델이 다양한 입력값에 대해 효과적인 학습을 수행할 수 있도록 돕고, 특성의 다양성을 확보함으로써 모델의 일반화 성능을 향상할 수 있다. 이러한 증강 기법이 TabNet 의 특성 선택 과정에서 특정 값에 대한 의존성을 완화하는 데 효과적으로 작용할 것이라 기대한다. 아래 그림 4-9 은 하나의 단일 데이터에 대해 3 가지의 증강 수치를 적용하여 증강한 예시 결과이다.




그림 4- 9. 데이터 증강 예시

5. 실험

5.1. 신호 처리 및 학습 모델의 파라미터 설계

5.1.1. 제안된 신호처리에 대한 파라미터 설정

학습 모델에 사용된 신호처리 파라미터는 표 5-1 와 같다. 지나치게 큰 주파수 대역은 필터링하고 데이터 수집에 사용된 센서의 감도를 고려하여 x_{max} 를 600 으로 설정한다. 또한 구간의 개수는 100 개이며 각 구간의 최소 단위는 0.1 로 설정한다. 이전 수식 8 과 같이 설정된 인자를 통해 주파수 간격이 자동으로 생성되고 그 간격에서 Peak(최댓값) 특징을 추출하여 데이터가 생성된다. 데이터 증강은 각 데이터마다 2회 이루어졌으며 0.5에서 1.5 사이의 수치의 값들을 사용하여 증강한다. 신호처리에서 3 가지의 스펙트럼을 하나로 합치는 가중 합 과정에서의 가중치는 가속도, 포락, 속도를 각각 0.6, 0.3, 0.1 로 설정하여서 할당한다. 가중치의 선정 배경은 센서의 원신호가 가속도계의 진동 센서 신호이기 때문에 원신호를 가장 큰 비중을 두어 사용하였고 앞서 분석에서 살펴본 것처럼 절삭 공정에서 중요한 배수 성분 신호를 잘 관측할 수 있는 포락 신호의 비중을 다음으로 높게 설정하였다. 속도 스펙트럼의 경우 포락의 저주파성 배수 성분도 포함하며 가속도계의 특성은 일부 줄어들었지만 여전히 그 성분을 포함하고 있는 것을 확인하였다. 따라서 속도의 비중을 0.1 로 낮게 설정하여 실험을 진행한다.

파라미터	값	설명
x_{min}	0.5	최소 X 값
x_{max}	600	최대 X 값
N	100	구간의 개수
d_{min}	0.1	최소 X 간격
Feature Type	Peak	추출되는 특징 종류
Number of augmentation	2	데이터 증강 횟수
augmented range	(0.5, 1.5)	증강 수치 범위
Spectrum Weight	$w_{Acc} : 0.6$	각 스펙트럼의 가 중 치
	$w_{Env} : 0.3$	
	$w_{vel} : 0.1$	

표 5- 1. 학습에 사용된 신호 처리 파라미터

5.1.2. 1D CNN 의 파라미터 설정

1D CNN 모델의 Layer 는 복잡도를 낮추고 과적합을 방지하여 일반화 성능을 향상하기 위해 3으로 설정하였다. 하이퍼 파라미터로는 합성곱 계층의 커널 크기는 3, stride 는 기본값인 1 로 설정하여 입력데이터의 세부적인 특징을 효과적으로 추출하도록 설계한다. 이와 함께 패딩을 1 로 설정하며 손실 함수는 Cross Entropy 손실 함수, 옵티마이저로는 Adam 을 선택하여 빠르고 안정적인 학습이 가능하게 하였다. Dropout 비율은 0.5 로 크게 설정하여 학습 과정에서 일부 뉴런을 무작위로 비활성화함으로써, 학습 과정에서 과적합을 방지하고자 하였다.

5.1.3. TabNet 의 파라미터 설정

TabNet 의 하이퍼 파라미터는 아래 표 5-2 와 같이 설정하였다. 디코더 차원(n_d)과 어텐션 차원(n_a)은 각각 256 으로 설정하여 각 특징 간의 복잡한 패턴을 충분히 학습하면서도 안정적인 학습 성능을 유지하도록 하였다. 학습 단계 수(n_{step})는 3 으로 설정하여 과 적합을 방지하는 데 초점을 두었다. Feature Reuse 계수(Γ)는 1.2 로 설정하여 이전 단계에서 학습한 정보를 적절히 재사용함으로써 데이터 특성을 점진적으로 학습하도록 설계하였다. Lambda sparse 는 0.01 로 설정하여 중요한 특성만 선택하도록 유도하며, 데이터의 노이즈를 줄이고 희소성을 강화하였다. 공유 레이어 수(n_{shared})는 3, 독립 레이어 수($n_{independent}$)는 2 로 설정하여 학습 단계별로 공통적인 패턴과 독립적인 특성을 균형 있게 학습할 수 있도록 하였다. 마지막으로 옵티마이저는 1D CNN 과 마찬가지로 Adam 을 사용하였다.

파라미터	값	설명
n_d	256	디코더 차원으로 특성을 학습하는 데 사용되는 임베딩 크기
n_a	256	어텐션 차원으로 입력 데이터의 중요도를 학습하는 임베딩 크기
n_{step}	3	학습의 단계 수로 Transformer 블록들로 구성됨
Γ	1.2	Feature Reuse 계수로, 이전 단계의 출력 재사용 빈도 조정
λ_{sparse}	0.01	특정 규제항을 적용하여 가중치를 조정
n_{shared}	3	각 스텝에서 공유되는 Shared Across Decision Steps 의 수
$n_{independent}$	2	각 스텝에서 공유되는 Decision Step Dependent 의 수

표 5- 2. 학습에 사용된 TabNet 의 파라미터

5.2. 교차 검증을 활용한 결함 분류 실험 설계

실험에 사용되는 최종 데이터는 그림 5-1과 같이 운전 RPM과 결함별로 각 3개의 세트로 구성된다. 첫 번째 실험에서는 교차 검증 방식으로 나누어 같은 운전 RPM 조건 아래에서 모델을 학습하고 학습에 사용되지 않은 검증 데이터로 모델을 평가한다. 각 실험은 아래의 표 5-3와 같이 이루어진다. 첫 번째 실험에서는 1번 데이터를 검증 세트로 사용하고, 2번과 3번 데이터를 학습 세트로 사용한다. 두 번째 실험에서는 2번 데이터를 검증 세트로 사용하고, 1번과 3번 데이터를 학습 세트로 사용한다. 이와 같은 방식으로 교차 검증(cross-validation)을 통해 모델의 성능을 더욱 안정적으로 평가하고, 일반화 능력을 평가할 수 있도록 실험을 설계하였다. 실험에서 TabNet과 1D CNN의 모델 학습은 모두 동일하게 배치 크기는 128, 학습 epoch은 50 epoch으로 설정한 뒤 학습 결과를 분석에 사용하였다.

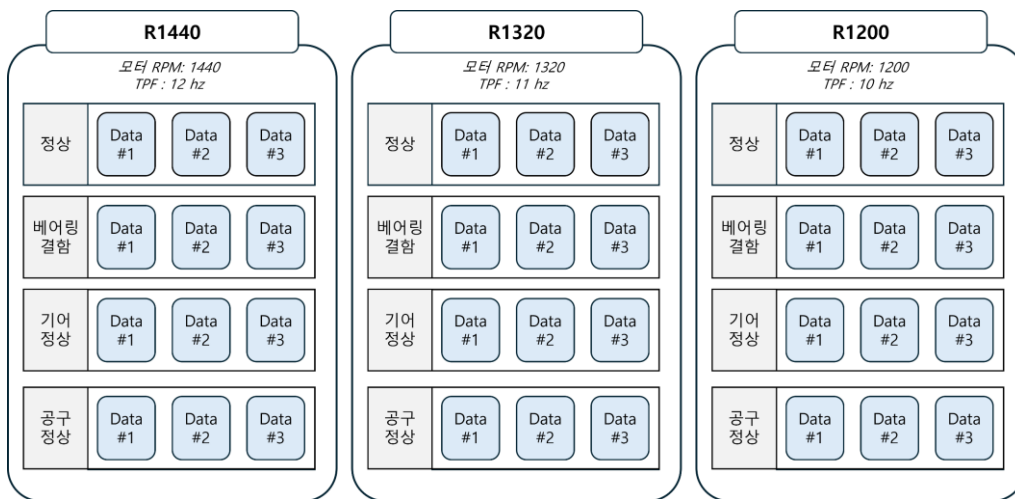


그림 5-1. 실험에 사용된 데이터 셋의 모습

실험 번호	학습 데이터	검증 데이터
#1 Validation	2 번 실험 & 3 번 실험	1 번 실험
#2 Validation	1 번 실험 & 3 번 실험	2 번 실험
#3 Validation	1 번 실험 & 2 번 실험	3 번 실험

표 5-3. 같은 운전 조건 내에서의 교차 검증 방식 예시

5.3. 실험 결과

5.3.1. 1Hz 단위의 단순 가속도 주파수 데이터

단순 가속도 주파수의 모터 데이터로 학습 후 검증한 결과

<i>Data Set</i>	<i>Model</i>	<i>AVG Validation Acc (%)</i>	<i>#1 Validation Acc (%)</i>	<i>#2 Validation Acc (%)</i>	<i>#3 Validation Acc (%)</i>
R1200	1D CNN	0.9262	0.9031	0.8756	1.00
R1200	TabNet	0.9201	0.8381	0.9631	0.9593
R1320	1D CNN	0.9634	1.00	0.90	0.9904
R1320	TabNet	0.9571	0.9607	0.9164	0.9942
R1480	1D CNN	0.9866	0.9598	1.00	1.00
R1480	TabNet	0.9158	0.8705	0.9560	0.9208
Average					
1D CNN	0.9587	TabNet	0.9310	Total	0.9410

표 5- 4. 신호 처리가 적용되지 않은 모터 데이터로 학습한 결과

단순 가속도 주파수의 스피들 데이터로 학습 후 검증한 결과

<i>Data Set</i>	<i>Model</i>	<i>AVG Validation Acc (%)</i>	<i>#1 Validation Acc (%)</i>	<i>#2 Validation Acc (%)</i>	<i>#3 Validation Acc (%)</i>
R1200	1D CNN	0.9934	0.9968	1.00	0.9834
R1200	TabNet	0.9385	0.9587	0.9140	0.9429
R1320	1D CNN	0.9673	1.00	0.9590	0.7090
R1320	TabNet	0.8569	0.9536	0.8754	0.7418
R1480	1D CNN	0.9995	0.9985	1.00	1.00
R1480	TabNet	0.9708	0.9330	0.9809	0.9985
Average					
1D CNN	0.9867	TabNet	0.9221	Total	0.9544

표 5- 5. 신호 처리가 적용되지 않은 스피들 데이터로 학습한 결과

5.3.2. 제안된 신호처리로 압축 및 변환된 주파수 데이터

신호처리가 적용된 모터 데이터로 학습 후 검증한 결과

<i>Data Set</i>	<i>Model</i>	<i>Average Validation Acc (%)</i>	<i>#1 Validation Acc (%)</i>	<i>#2 Validation Acc (%)</i>	<i>#3 Validation Acc (%)</i>
R1200	1D CNN	0.9361	0.9603	0.9969	0.8511
R1200	TabNet	0.9909	0.9984	0.9985	0.9759
R1320	1D CNN	0.9343	0.9946	0.9574	0.8511
R1320	TabNet	0.9865	1.0	0.9836	0.9759
R1480	1D CNN	0.9852	0.9762	0.9795	1.0
R1480	TabNet	0.9891	0.9717	0.9956	1.0
Average					
1D CNN	0.9519	TabNet	0.9883	Total	0.9701

표 5- 6. 신호 처리가 적용된 모터 데이터로 학습한 결과

신호처리가 적용된 스피들 데이터로 학습 후 검증한 결과

<i>Data Set</i>	<i>Model</i>	<i>Average Validation Acc (%)</i>	<i>#1 Validation Acc (%)</i>	<i>#2 Validation Acc (%)</i>	<i>#3 Validation Acc (%)</i>
R1200	1D CNN	0.9705	0.9921	0.9871	0.9323
R1200	TabNet	0.9747	0.9667	0.9846	0.9729
R1320	1D CNN	0.9967	0.9982	0.9918	1.0
R1320	TabNet	0.9638	1.0	0.9820	0.9094
R1480	1D CNN	0.9995	0.9985	1.0	1.0
R1480	TabNet	1.0	1.0	1.0	1.0
Average					
1D CNN	0.9889	TabNet	0.9795	Total	0.9842

표 5- 7. 신호 처리가 적용된 스피들 데이터로 학습한 결과

5.4. 실험 결과 분석

5.4.1. 학습 알고리즘과 신호 처리 유무 간의 검증 성능 비교




그림 5- 2. 학습 알고리즘 별 성능 비교

그림 5-2 는 제안된 신호 처리의 유무에 따른 모델별 검증 정확도에 대한 박스 플롯을 나타낸 결과이다. 1D CNN 의 경우에는 신호 처리가 이루어지지 않은 단순한 주파수 데이터와 신호 처리가 이루어진 데이터 모두 비슷한 성능을 보여 주며 약간의 성능 개선이 확인되었다. 반면에 TabNet 의 경우에는 제안한 신호 처리 기법을 적용한 인공 지능 모델의 검증 정확도가 평균이나 편차 등에서 모두 우수한 성능을 보여주었다. 신호처리가 이루어지지 않은 1D CNN 의 경우 필터 연산을 통한 CNN 의 특징 추출이 효과적으로 작용하여 신호 처리를 적용하지 않은 모델 또한 성능이 크게 떨어지지 않은 것으로 추측된다. TabNet 의 경우에는 단순한 주파수 학습 셋의 경우 어텐션 메커니즘의 특징 선택 알고리즘이 큰 효과를 발휘하지 못한 것으로 보이며, 제안된 신호처리를 적용한 TabNet 의 모델의 경우 제안된 신호 처리 알고리즘을 통해 추출된 정보와 TabNet 의 Sparse 어텐션 메커니즘이 결합하여 중요한 특징을 효과적으로 학습하여 성능을 크게 개선한 것으로 해석된다.

결과적으로 제안된 신호처리 알고리즘은 1D CNN 과 TabNet 모델에서 학습 데이터에 활용되었을 때 더 적은 데이터의 특징 개수를 사용함에도 검증 성능을 향상하는데 기여하는 것으로 판단된다. 이는 TabNet 과 같은 특징 선택을 기반으로 하는 모델에서 제안된 신호 처리 알고리즘을 활용하였을 때 학습 효율성 및 성능을 극대화할 수 있음을 시사한다.

5.4.2. 센서 설치 위치 및 종류 간의 검증 성능 비교




그림 5-3. 센서 설치 위치 별 성능 비교

그림 5-3 은 센서의 설치 위치 및 민감도 별로 구분하여 각 실험의 검증 정확도를 비교하여 분석한 결과이다. 단순 주파수 데이터의 경우 1D CNN 모델이 센서 위치별로 검증 정확도에서 큰 변동성을 보였으며 TabNet 모델은 성능은 전체적으로 저조했다. 또한 1D CNN 모델에서는 학습 데이터로 500mV/g 의 진동 센서의 데이터를 사용한 경우 100mV/g 센서 데이터를 사용한 경우보다 비교적 검증 성능이 우수했다. TabNet 의 경우에는 모두 성능이 낮았다. 제안된 신호처리 알고리즘 적용 유무에 따른 분석에서는 TabNet 모델은 적용 전후로 큰 성능 차이를 나타냈으며 안정적인 검증 정확도를 보였다. 또한 센서별 분석에서도 비슷한 형태의 박스 플롯을 나타내면서 검증 정확도의 편차가 줄어들어 일반화 능력이 향상되었음이 추측된다. 1D CNN 모델 또한 신호처리를 적용 후 성능 개선이 확인되었다.

결과적으로 제안된 신호처리를 적용한 데이터로 학습된 모델이 평가에서 안정적인 검증 성능을 보여 주었으며 센서 설치 위치를 구분하지 않고 모든 모델에서 분류 성능 향상을 나타내었다. 이는 제안된 신호 처리 알고리즘이 모델의 일반화 능력을 높이는 데 중요한 역할을 수행할 수 있음을 시사한다.

5.4.3. 학습 데이터 셋 종류별 검증 성능 비교

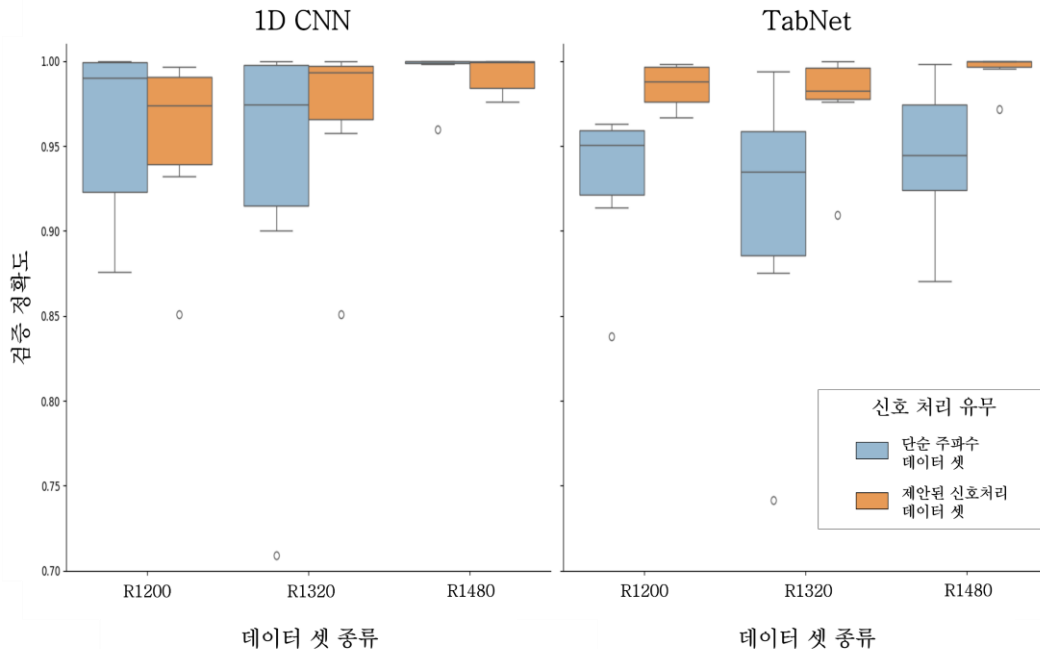


그림 5- 4. 학습 데이터 종류 별 성능 비교

그림 5-4 는 모터와 스핀들 위치의 센서 데이터를 구분하지 않고 모터의 운전 속도를 기준으로 분리하여 박스 플롯 형태로 분석한 결과이다. 1D CNN 의 경우 단순 주파수 데이터로 학습한 경우 R1200 과 R1320 데이터 셋에 대해 비교적 낮은 검증 정확도를 보여주었지만, R1480 의 높은 절삭 속도에서는 높은 검증 정확도를 나타냈다. 제안된 신호처리를 적용한 데이터로 학습된 모델은 R1200 과 R1320 에서 약간의 성능 개선을 보였다. 단순 주파수 데이터로 학습된 TabNet 모델의 경우는 1D CNN 모델에 비교해 성능이 크게 떨어지는 것이 확인된다. 반면에 제안된 신호처리를 적용한 데이터로 학습된 TabNet 모델은 분류 정확도가 크게 개선되었으며 편차가 줄어들고 전체적으로 안정적인 분류 성능을 나타내는 것을 확인하였다.

실험 결과를 정리하면 제안된 신호 처리의 적용 유무가 TabNet 과 1D CNN 모델 모두 성능 향상을 나타냈으며 비교적 R1480 의 데이터 셋에서 높은 분류 성능을 나타냈다. 이전 실험과 마찬가지로 제안된 신호처리 알고리즘과 TabNet 의 특징 선택 기반의 학습 알고리즘의 결합이 결합 분류에 효과적으로 작용한 것이 실험에서 확인된다. 제안된 신호 처리 알고리즘을 적용한 TabNet 모델이 데이터 셋의 종류를 구분하지 않고 분류 성능이 우수하고 큰 편차를 가지지 않는 안정적인 결과를 나타냈다. 이는 제안된 신호 처리 알고리즘이 TabNet 모델의 학습에서 일반화 능력을 향상하는데 영향을 끼치는 것으로 분석된다.

5.5. TabNet 의 Feature Importance

5.5.1. 전역적 특징 중요도




그림 5- 5. 모터 데이터로 학습 모델의 전체 Feature Importance

그림 5-5 은 모터 RPM 1200 운전 상황에서 모터 측에 부착된 100mV/g 진동 센서 데이터를 통해 학습된 모델의 특징 중요도를 나타낸다. TabNet 알고리즘은 Attentive Transformer 와 Mask 기반의 학습을 통해 인스턴트의 특징 선택을 기록하여 학습 동안의 모델의 특징 중요도를 계산하는 것이 가능하다. 따라서 이를 활용하여 데이터셋에서 어떤 데이터의 활용 비중이 높았는지에 대한 분석이 가능하다. 제안된 신호처리 적용한 데이터 셋으로 학습된 모델은 회전 성분 기반의 구간의 특징들을 학습으로 사용하기 때문에 설명 가능성을 더욱 높여주는 결과를 나타낸다. 모터 쪽의 특징 중요도에서는 1X 의 특징이 저주파에서 강하게 선택되었고 TPF 성분인 2X 특징 또한 주변부에 비해 많이 활용되었다. 3X 의 경우에는 거의 선택되지 않았다. 또한 전체적으로 특징들이 전 대역에서 고르게 사용되었으며 50X 및 200X 부근의 특징들이 많이 활용된 것을 분석할 수 있다.




그림 5- 6. 스핀들 데이터로 학습된 모델의 전체 Feature Importance

그림 5-6 은 모터가 1200 RPM 운전하는 상황에서 스핀들 측에 부착된 500mV/g 진동 센서 데이터를 통해 학습된 모델의 특징 중요도를 나타낸다. 특징 중요도를 나타낸 결과에서 이전 모터 측의 센서 데이터로 학습된 모델의 특징 중요도와 비교해서 상당히 특징들의 선택 빈도가 낮은 모습을 나타낸다. 또한 상대적으로 저주파 영역에서 1X 와 2X 성분을 중요하게 사용하는 것을 확인하였다. 고주파 영역에서는 124X ~ 133X 구간의 특징이 많이 활용되는 것을 확인할 수 있다. 이러한 과정을 통해 학습 모델별로 학습에 사용된 회전 성분 구간의 중요도를 분석하여 모델이 신뢰 가능한 모델인지 분석하는 것이 가능하다. 모델이 저주파 구간에서 절삭 공정과 관련된 TPF 와 1X 성분 등의 특징에 대해서 중요도를 측정하였지만 고주파의 특징과 그 외의 배수 성분들의 중요도를 평가하지 않은 점으로 보아 추가적인 분석이 필요해 보인다. 또한 모터 데이터로 학습된 모델과 비교하여 특징을 전체적으로 사용하지 않고 일부 주파수 구간을 선택적으로 사용한 점에 대해서도 모델 별로 비교하여 추가적인 분석이 요구된다.

5.5.2. Step 단위의 특징 중요도

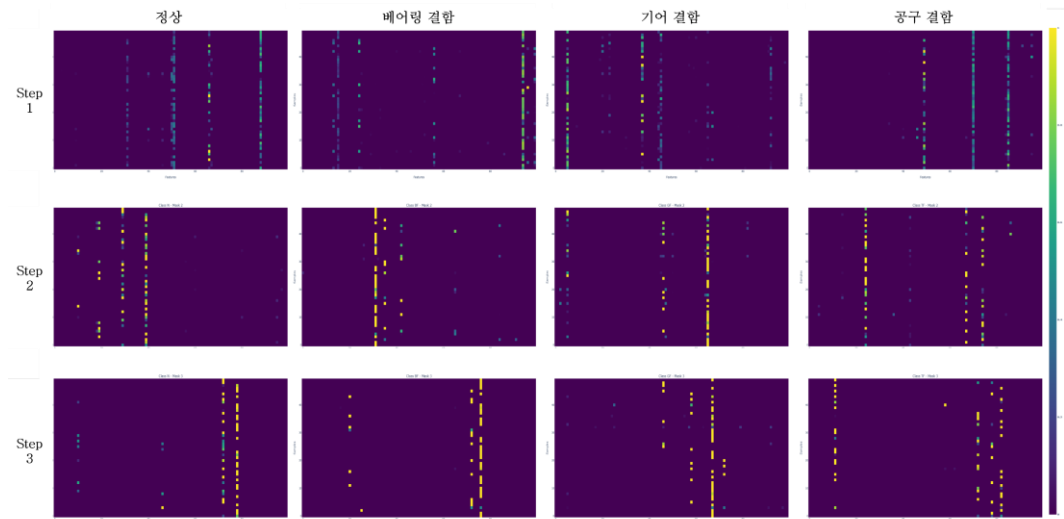


그림 5- 7. 모터 학습 모델의 Step 별 Feature Importance

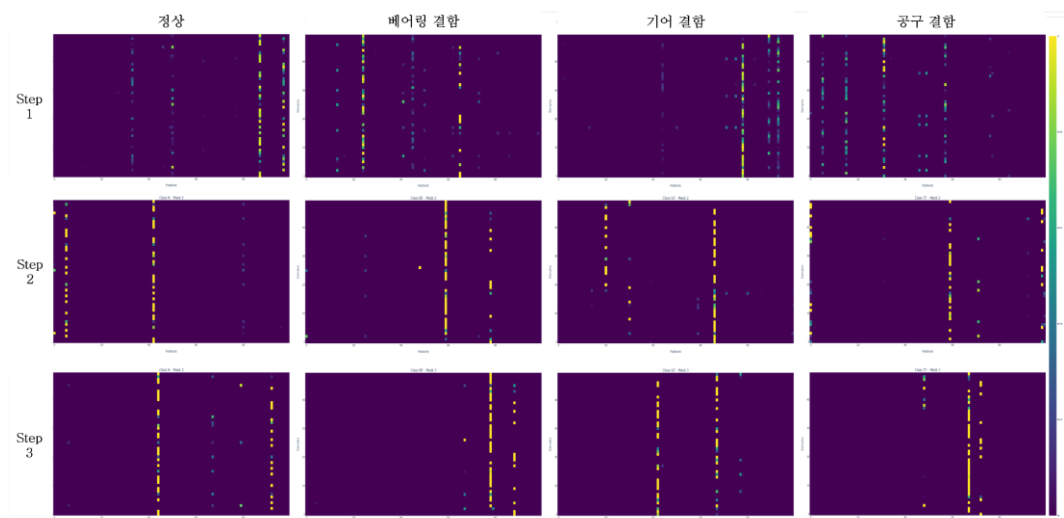


그림 5- 8. 스핀들 학습 모델의 Step 별 Feature Importance

그림 5-7 과 5-8 은 각 센서에서 수집한 데이터를 학습하여, 각 결함 레이블의 특징 선택을 Step 단위로 시각화한 결과를 나타낸다. TabNet 은 학습 과정에서 Step 단위로 변수 선택과 중요도를 계산하며, 이를 통해 학습 데이터에서 중요한 특징을 효과적으로 학습하는 구조를 가지고 있다. 이러한 특성을 활용하면, 결함별로 회전 성분 대역에서 나타나는 특징적인 변화를 분석할 수 있으며, 설비 결함 진단 과정에서 설명 가능성을 효과적으로 제공할 수 있다. 이러한 TabNet 알고리즘의 특징과 제안된 신호처리 기법을 활용하여 설비의 결함 판별과 함께 그에 대한 이유까지 설명할 수 있는 인공지능으로 발전하는 것이 가능할 것이라 기대한다.

6. 결론

본 연구는 제조업 설비 중 동작기계 설비에서 자주 발생하는 결함 분류를 위한 회전 성분 기반의 신호처리 및 그를 활용한 인공지능 알고리즘을 제안한다. 연구에서는 MCT 테스트베드를 활용하여 정상, 베어링 결함, 기어 결함, 공구 결함을 모사한 뒤 데이터를 수집하였고 이를 분석하였다. 본 연구에서 개발한 신호처리 알고리즘은 특정 인자에 따라 회전 성분과 특징값을 활용하여 압축 및 처리를 수행한다. 저주파 영역의 특성은 세밀하게, 고주파 영역의 특성은 크게 샘플링하여 생성된 구간들에 각 특징 값을 추출하여 신호를 압축한다. 이 때 신호 처리에 사용되는 인자를 통해 진동 데이터를 압축하고 해상도를 조절할 수 있다. 또한 가속도계 센서 데이터를 속도 및 포락 스펙트럼으로 변환한 후, 가속도 스펙트럼과 가중합 처리하여 신호를 재구성함으로써 특징 보존과 신호의 다양성을 확보한다.

인공지능에 활용된 알고리즘에는 결함 분류에서 자주 활용되는 1D CNN 과 함께 추가로 TabNet 알고리즘을 활용한다. 단순한 1Hz 단위의 주파수 데이터와 제안된 신호처리가 적용된 데이터 셋으로 각 모델을 학습하여 결과를 분석한 결과 제안된 신호처리 기법을 통해 학습된 모델이 단순한 주파수 데이터를 학습한 모델에 비해 더 우수한 검증 성능을 보이는 것을 확인했다. 또한 센서 위치 및 민감도, 운전 환경 등의 비교를 통해 검증한 결과에서 단순한 1Hz 단위의 데이터로 학습한 TabNet 모델에 비해 제안된 신호처리로 변환된 데이터를 학습한 TabNet 모델이 안정적이고 높은 성능을 보이는 것을 분석했다. 이는 합성곱 기반의 특징 추출 메커니즘의 영향으로 단순한 1Hz 데이터 셋에서도 결함 분류에 있어 일정 수준 이상의 정확도를 유지한 1D CNN 과 달리 TabNet 은 Sparse Attention 메커니즘을 통해 주요 특징을 선택적으로 학습하는 구조를 가지기 때문에 제안된 신호처리 데이터를 활용할 때 더 높은 성능과 안정성을 보이는 것으로 판단된다. 따라서 TabNet 알고리즘과 제안된 신호처리 알고리즘이 결합했을 때 회전 성분 영역에서 핵심 성분을 효과적으로 선택하고 학습하는 것을 확인했다. 또한 다양한 실험 환경에서 검증하였을 때 일반화 성능을 향상시킬 수 있음을 검증했다.

모델의 설명 가능성을 분석하기 위해 TabNet 과 제안된 신호처리 방식을 사용한 모델에서 전역적 회전 성분 특징 중요도와 Step 단위의 회전 성분 특징 중요도를 분석했다. 전역적 특징 중요도는 센서를 기준으로 모터 데이터는 넓은 주파수 대역에서, 스피들 데이터는 특정 회전 성분 대역에서 집중되는 경향을 보이는 것을 해석했다. TabNet 의 학습 과정을 Step 단위로 구분하여 특징 중요도를 시각화한 결과, 각 결함 레이블에 따른 주요 주파수 대역에서의 특징 선택 변화를 확인할 수 있었다. 이는 TabNet 의 특징 선택 메커니즘과 제안된 회전 성분 기반의 신호처리 알고리즘을 통해 데이터의 중요한 정보를 단계적으로 학습하고 시각화 하여 결함 진단에 대한 설명 가능성을 보일 수 있음을 시사한다.

결론적으로, 본 연구에서 제안된 신호처리 기법과 인공지능 알고리즘의 결합은 MCT 설비에서 발생하는 주요 결함 분류와 딥러닝 모델의 일반화 문제를 효과적으로 해결할 수 있음을 입증한다. 제안된 신호처리 기법에서 특정 인자를 기준으로 진동 데이터를 효율적으로 압축하고 회전 성분 단위의 특징을 보존함으로써, 데이터의

저장 및 처리 비용을 줄이는 동시에 인공지능 모델의 학습 효율성을 높일 수 있다. 또한 알고리즘의 인자를 통해 통합된 구조를 제시하며 데이터 표준화의 가능성을 제시한다. 이를 활용한 딥러닝 학습 결과에서 제안된 신호처리와 TabNet 알고리즘의 Sparse Attention 메커니즘의 결합이 MCT 설비의 결합과 관련된 회전 성분의 핵심 특징을 단계적으로 선택하고 학습하여 결합 분류의 정확도와 설명 가능성을 크게 향상시켰다. 또한 특징 중요도 분석을 통해 TabNet 이 각 데이터의 특성과 결합 유형에 따라 주요 회전 성분 특징을 효과적으로 활용하는 경향을 확인하였으며, 이는 모델이 단순한 예측을 넘어 설명 가능성을 제공할 수 있음을 보여준다.

본 연구는 MCT 설비의 결합 진단 문제를 해결하기 위한 새로운 접근법을 제시하며, 제조 산업의 디지털 전환과 예지보전 시스템 고도화에 실질적인 기여를 할 수 있는 신호처리 및 딥러닝 기반의 기술을 제공하였다. 이는 향후 스마트 제조 환경에서 인공지능 기반 설비 진단 및 유지보수 시스템 확보에 큰 도움이 될 것으로 기대된다.

참고 문헌

- [1] 강성우. (2019). 스마트 팩토리용 설비 예지보전 모델의 분석 및 제언. 국내석사학위논문, 연세대학교 공학대학원.
- [2] 유기성, 문영민. (2020). 스마트공장 설비진단 및 예지보전 기술의 발전 동향. 한국통신학회지(정보와통신), 37(7), 36-42.
- [3] 박은식, 김한식. (2008). NC 선반 절삭공구마모 문제점 보정을 위한 CNC 성능개선 시스템 연구. 한국산업응용학회 논문집, 11(3), 135-140.
- [4] 임현진, 강재민, 구본유, 권선영. (2021). 음성 특징 추출기법을 활용한 진동 신호의 CNC 공구 마모도 예측. 한국정보과학회 학술발표논문집, 제주.
- [5] Sohaib, M., Kim, C.-H., & Kim, J.-M. (2017). A hybrid feature model and deep-learning-based bearing fault diagnosis. *Sensors*, 17(12), 2876. <https://doi.org/10.3390/s17122876>.
- [6] 박병희, 이윤제, 이창우. (2020). Tool Condition Monitoring Using Deep Learning in Machining Process. *Journal of the Korean Society for Precision Engineering*, 37(6), 415-420. <https://doi.org/10.7736/JKSPE.020.040>
- [7] Shin, D.-J., Park, J.-H., Kim, J.-H., Kwak, K.-J., Park, J.-M., & Kim, J.-J. (2019). Big Data-based Sensor Data Processing and Analysis for IoT Environment. *The Journal of the Institute of Internet, Broadcasting and Communication*, 19(1), 117-126. <https://doi.org/10.7236/IIBC.2019.19.1.117>
- [8] Cheon, K. M., & Yang, J. (2021). Explainable AI Application for Machine Predictive Maintenance. *Journal of Society of Korea Industrial and Systems Engineering*, 44(4), 227-234. <https://doi.org/10.11627/jksie.2021.44.4.227>
- [9] Wang, X., Mao, D., & Li, X. (2021). Bearing fault diagnosis based on vibro-acoustic data fusion and 1D CNN network. *Measurement*. Elsevier BV. <https://doi.org/10.1016/j.measurement.2020.108518>
- [10] Arik, S. Ö., & Pfister, T. (2019). TabNet: Attentive interpretable tabular learning. arXiv preprint. <https://arxiv.org/abs/1908.07442>
- [11] 김대경, 신상욱. (2007). 예방보전이 불완전할 때 최적 주기적 예방보전 계획. *Journal of Korean Society for Quality Management*, 35(4), 140-146.
- [12] Cooley, J. W., & Tukey, J. W. (1965). An Algorithm for the Machine Calculation of Complex Fourier Series. *Mathematics of Computation*, 19(90), 297-301. <https://doi.org/10.2307/2003354>
- [13] 김주영, 이상호, 임순현, 김종면. (2023). 재생성 포락 스펙트럼을 활용한 1D CNN 기반 화학설비교반기 결함검출 연구. 한국통신학회 학술대회논문집, 경북 -

- [14] 한재민, 이재웅, 조영욱, 임순현, 이재욱, 김재영, 김종면. (2024). 진동 주파수 스펙트럼 데이터 및 CNN 기반 회전수에 적응적인 베어링 결함 검출 알고리즘 연구. 유공압건설기계학회 학술대회논문집.
- [15] Coraggio, E., Gronow, C., Tryfonas, T., & Han, D. (2023). Low-pass filter application for noise removal in water quality data with high temporal resolution. Research Square. <https://doi.org/10.21203/rs.3.rs-2117131/v1>
- [16] LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1(4), 541-551. <https://doi.org/10.1162/neco.1989.1.4.541>
- [17] Kim, J.-W., Jang, J.-S., Yang, M.-S., Kang, J.-H., & Kim, K.-W. (2019). A Study on Fault Classification of Machining Center using Acceleration Data Based on 1D CNN Algorithm. *Journal of the Korean Society of Manufacturing Process Engineers*, 18(9), 29-36. <https://doi.org/10.14775/ksmpe.2019.18.9.029>
- [18] 이재웅, 감민성, 손동구, 김종면. (2023). 1D CNN 기반 석유화학 회전기기 복합 고장 진단에 관한 연구. 한국통신학회 학술대회논문집, 경북.
- [19] Berahmand, K., Daneshfar, F., Salehi, E. S., Li, Y., & Xu, Y. (2024). Autoencoders and their applications in machine learning: A survey. *Artificial Intelligence Review*, 57(28). <https://doi.org/10.1007/s10462-023-10662-6>
- [20] Dauphin, Y. N., Fan, A., Auli, M., & Grangier, D. (2017). Language modeling with gated convolutional networks. arXiv preprint. <https://arxiv.org/abs/1612.08083>
- [21] Martins, A. F. T., & Astudillo, R. F. (2016). From Softmax to Sparsemax: A Sparse Model of Attention and Multi-Label Classification. arXiv preprint. <https://arxiv.org/abs/1602.02068>
- [22] Vibrasens. (2022). VS 101.51 Datasheet. Vibrasens. https://vibrasens.co.kr/wp-content/uploads/2022/catalogue/IEPE/TOP/VS_101.51_Datasheet.pdf

[영문 요약]

Development of a Signal Processing Algorithm and Research on Deep Learning-Based Condition Classification for Machine Tool Health Diagnosis

This study proposes a rotational component-based signal processing algorithm to effectively diagnose major defects occurring in machine tool Equipments and efficiently manage data, aligning with the global manufacturing industry's competitive enhancement and the digital transformation of the domestic manufacturing sector. Additionally, research was conducted on a deep learning-based state classification algorithm and explainable artificial intelligence utilizing the proposed signal processing algorithm. The data used in this study were collected through an MCT testbed by simulating normal conditions, bearing defects, gear defects, and tool defects in the equipment. Data were collected during material processing under various cutting speeds and environmental conditions. The acquired data were analyzed intensively for cutting and defect-related components through time-series analysis, velocity, acceleration, and envelope spectrum analysis.

The proposed signal processing technique is designed to compress large-scale vibration data efficiently by preserving the characteristics of major harmonic components in the low-frequency range during cutting processes. This is achieved by applying dense sampling in the low-frequency region and sparse sampling in the high-frequency region, thereby maintaining the characteristics of cutting processes while reducing storage costs. The method also provides a unified data structure through specific parameters, enabling the conversion of data collected from different equipment and environments into a standardized format, thereby establishing a framework for cross-industry data standardization. This study proposes the use of TabNet, alongside the widely used 1D CNN, in the frequency domain for defect diagnosis. The 1D CNN provides learning through filter-based feature extraction mechanisms, while TabNet employs a Sparse Attention mechanism to sequentially select and learn key features from the data, offering explainability and enhancing the reliability of prediction results. In particular, the study aims to effectively learn the characteristics of important rotational components used for defect classification through TabNet's feature selection mechanism and the proposed rotational component-based signal processing. Additionally, it seeks to visually present these important rotational characteristics, thereby enhancing explainability.

The results of this study confirmed that the combination of the proposed signal processing algorithm and deep learning algorithms effectively addresses the defect classification problems in MCT equipment. Comparing the performance of learning models with and without the proposed signal processing, both 1D CNN and TabNet models trained on the processed dataset showed improved defect classification performance. In particular, TabNet exhibited lower validation accuracy and higher variability when trained on simple frequency data without signal processing. However, when trained on the processed data, the Sparse Attention mechanism effectively learned the characteristics of specific rotational components, resulting in significant performance improvements. Additionally, the combination of the TabNet algorithm and the proposed signal processing demonstrated substantial performance enhancements across analyses involving differences in sensor installation locations, sensitivities, and cutting speeds.

In terms of explainability, the integration of TabNet and the proposed signal processing enabled the visualization of the importance of rotational component characteristics. Furthermore, it was possible to analyze the patterns of key frequency features selected at each learning step, known as "Step" in TabNet, for each defect type. This sets it apart from traditional black-box deep learning models by identifying importance frequency feature intervals at each step and providing explainability for defect classification.

In conclusion, the integration of the proposed signal processing algorithm and deep learning algorithms was proven to be effective for defect diagnosis in MCT equipment. Moreover, the explainability of the TabNet model extends beyond mere prediction performance, contributing to a better understanding of defect causes by visually analyzing important rotational component characteristics. These results provide practical strategies for leveraging data in the digital transformation of the manufacturing industry and advancing smart factory initiatives. They are expected to contribute to the development of reliable diagnostic models with enhanced applicability across diverse equipment and environments.

keyword:

Machine Tool, Condition Classification, Signal Processing, Deep Learning, TabNet, 1D-CNN, Explainable AI (XAI)