

생산 공정에서 CNN을 이용한 음향 PSD 영상 기반 공구 상태 진단 기법

이경민*

Sound PSD Image based Tool Condition Monitoring using CNN in Machining Process

Kyeong-Min Lee*

*Assistant Professor, Department of Computer Engineering, Silla University, Busan, 46958 Korea

요 약

정보통신기술(ICT)를 적용한 스마트팩토리로 불리는 지능형 생산 공장은 각종 센서를 통해 공정 데이터를 실시간으로 수집하고 있다. 이렇게 수집된 데이터를 효과적으로 활용하는 연구가 많이 진행되고 있는데, 본 논문에서는 생산 공정에서 발생하는 음향 신호를 기반으로 공구 상태를 진단하는 기법을 제안한다. 첫 번째로 결함이 있는 공구를 감지할 뿐만 아니라 공회전 및 공정 운용에 따른 다양한 공구 상태를 제시한다. 두 번째로 푸리에 분석을 이용하여 사운드의 전력스펙트럼을 영상으로 표현하고, 데이터에 숨겨진 건강한 패턴을 드러내고, 강조하기 위해 일부 변형을 적용한다. 마지막으로 이렇게 획득한 대비 강화된 PSD 영상은 CNN을 이용해 상태별로 진단한다. 그 결과 제안한 음향 PSD 영상 + CNN 방법은 데이터의 차별화된 특징이 잘 반영되어 공구 상태에 따른 높은 진단 결과를 보여준다.

ABSTRACT

The intelligent production plant called smart factories that apply information and communication technology (ICT) are collecting data in real time through various sensors. Recently, researches that effectively applying to these collected data have gained a lot of attention. This paper proposes a method for the tool condition monitoring based on the sound signal generated in machining process. First, it not only detects a fault tool, but also presents various tool states according to idle and active operation. The second, it's to represent the power spectrum of the sounds as images and apply some transformations on them in order to reveal, expose, and emphasize the health patterns that are hidden inside them. Finally, the contrast-enhanced PSD image obtained is diagnosed by using CNN. The results of the experiments demonstrate the high discrimination potential afforded by the proposed sound PSD image + CNN and show high diagnostic results according to the tool status.

키워드 : 공구 상태 진단, 전력스펙트럼밀도, 합성곱신경망, 가공 공정, 음향 신호

Keywords : Tool Condition Monitoring, PSD(Power Spectral Density), CNN(Convolution Neural Network), Machining Process, Sound Signal

Received 4 April 2022, Revised 12 April 2022, Accepted 21 June 2022

* Corresponding Author Kyeong-Min Lee(E-mail:kmlee2k@silla.ac.kr, Tel:+82-51-999-5374)
Assistant Professor, Department of Computer Engineering, Silla University, Busan, 46958 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.7.981>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

일반적으로 제조 산업에서는 제품을 생산하기 위하여 생산 공정을 가동하여 공정 별로 의도된 작업을 수행하는 생산 설비를 운용한다. 이 때, 공정에서는 생산물을 향상시키기 위하여 지속적으로 설비를 운용하지만, 설비가 지속적으로 사용되는 경우 설비에 투입되는 장비 및 공구의 열화가 이루어진다.

최근에는 스마트팩토리 기술이 발전함에 따라 각종 센서와 통신장비를 통해 공정 데이터를 실시간으로 수집하여 제조 공정의 상태를 모니터링 하고, AI 기술이 접목된 체계적인 분석 및 관리를 통해 생산성을 높이고 있다. 특히 가공공정은 제품 제조 과정에서 필수적이며, 공구 파손을 방지하고 고장 위험을 줄이려면 효과적인 모니터링 시스템이 필요하다[1-3].

가공공정은 소재의 특성과 형상을 고려하여 인서트, 엔드밀, 비트 등 다양한 공구가 사용된다. 공구는 소재를 가공하면서 발생하는 절삭 저항과 마찰로 인해 마모되고, 심한 경우 파손까지 발생한다. 이 때 발생하는 신호를 수집하고, 수집된 정보를 통해 고장 여부를 진단하는 방법으로 이 분야에 관한 연구들이 오래전부터 진행되고 있다[4, 5].

기존에는 공구 상태를 확인하는 방법으로 작업자의 경험과 감각에 의존하다 보니 공구에 문제가 발생하더라도 즉시 감지가 불가능하고, 작업을 마친 후에야 제품의 불량을 인지하고 역으로 추적하여 공구 문제를 발견하는 상황이었다. 공구의 상태를 사전에 진단하고 파손을 감지할 수 있는 시스템이 구축된다면, 작업자는 단편적인 조치로 적절한 시기에 공구를 미리 교체하여 공정의 문제 발생과 제품의 품질 저하를 방지할 수 있다. 한 걸음 더 나아가 생산 데이터를 축적하여 공구의 수명까지 예지할 수 있다면, 업무의 효율성 및 생산성, 제품의 품질 향상 등 가공 공정에서의 산업 경쟁력을 높이는 데 기여할 수 있을 것이다.

본 논문에서는 정밀가공 공정에서 많이 사용하는 절삭 공구 상태를 진단하는 목적으로 비접촉 장점을 가진 디지털 녹음 장치를 사용하여 제품의 정상과 불량품으로 진행될 때 발생하는 공구 상태의 정보를 수집한다. 수집한 정보를 기반으로 CNN을 이용해 공구 상태를 진단한다. 또한 진동 데이터와 달리 절삭 공구에서 생성된 음향 신호의 주파수 기반 특징을 효율적으로 처리할 때

시간-주파수 영역 기반의 특징을 능가할 수 있음을 보여준다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구로 고장 진단 및 공구 상태 진단 기술에 대해 정리하고, 3장에서는 제안하는 방법으로 데이터 수집에서 데이터 고유한 특성을 강조하기 위한 전처리, 딥러닝 기반의 학습 모델을 설명한다. 4장에서는 학습한 모델의 공구 상태 진단에 대한 결과와 다른 방법과의 비교 연구를 살펴본다. 5장에서는 연구의 결론을 정리한다.

II. 관련 연구

고속 가공공정은 높은 정확도와 정밀도로 주목받고 있지만, 마모로 인한 제품 품질 저하와 잦은 공구 교체로 인한 제품 원가 상승은 가공 공정의 주요 문제이다. 공구와 공작물의 상호 작용으로 인해 가공 중 절삭 공구의 날카로운 모서리가 변형되거나 손상되는 것을 공구의 마모라 한다. 공구의 수명 예측 및 공구 교체는 과거 실험에서 얻은 공구 마모 데이터에서 추정된 공구 수명을 기반으로 한다. 절삭 공구 상태 예측은 모든 제조 공정이 비선형 시스템이기 때문에 어렵고, 또한 절삭 시 각종 센서에서 수집되는 신호는 가공 조건 및 공구 마모에 따라 달라지기 때문에 마모를 예측하거나 모델링하기가 쉽지 않다. 공구 마모는 직접 또는 간접 방법으로 측정할 수 있다. 직접적인 방법은 절삭공구를 기계에서 제거해야 하며 일반적으로 Tool Makers Microscope나 Optical Microscope를 사용하여 마모를 측정한다[6]. 시간이 더 많이 걸리고 기계 가동 중지 시간이 늘어나는 반면 간접법은 생산 속도에 영향을 주지 않고, 다양한 센서 신호(음향 방출, 밀링력, 공구/공작물 진동, 사운드, 스피들 토크, 스피들 모터 전류 및 전력, 온도)를 활용하여 공구 마모를 추정한다.

Kankar et al. [7]는 볼 베어링 진동 데이터의 시계열을 사용하여 6개의 통계적 특징을 계산하고 이를 신경망(NN) 기반 분류기의 입력으로 사용했고, Saimurgan et al. [8]은 사운드 및 진동 데이터에 대한 11가지 통계적 특징을 계산했다. [7]에서 사용된 6가지 특징과 5가지 특징을 더 추가하여 SVM을 이용해 진단했다. 시간-주파수 영역 기반 기능의 일부로 Wang et al. [9]은 사운드 데이터를 사용하여 특징 추출로 HHT(Hilbert-Huang

transform)을 이용하고, SVM을 적용하여 자동차 엔진의 결함 진단을 수행했고, LEE et al. [10]는 DWT (Discrete Wavelet Transform)와 ANN을 이용하였다. 딥러닝[11]이 시작된 이후 많은 연구에서 높은 수준의 자동 특징 추출 방법을 사용하거나 hand-crafted 특징 추출과 결합하여 사용하였다. Jia et al. [12]는 SAE(Stacked Auto-encoder)의 입력으로 회전 기계에서 진동 데이터의 원시 시계열을 사용하였고, Verstraete et al. [13]은 STFT를 deep CNN의 입력으로, Zhao et al. [14]은 WP를 DRN(Deep Residual Network)의 입력으로 사용하였다. 또한 Lu et al. [15]와 Guo et al. [16]는 회전 베어링의 고장 진단을 위해, Sun et al. [17]은 유도 전동기 결함 진단을 위해 CNN을 사용하여 정확도를 높였다.

III. 제안한 공구 상태 진단 기법

본 논문에서는 가공 중 절삭 공구에서 발생하는 음향 신호를 기반으로 공구 상태를 진단하는 방법을 제안한다. 그림 1은 CNN을 이용한 음향 PSD 영상 기반 공구 상태를 진단 과정으로, 수집된 1차원 시계열 데이터는 주파수 영역 기반의 전력스펙트럼밀도를 이용하여 2차원 영상으로 표현하고, 데이터에 숨겨진 결함 패턴을 드러내고 강조하기 위해 전처리를 적용한다. 이렇게 생성된 PSD 영상은 CNN을 이용해 공구 상태를 진단하게 된다.

3.1. 학습 데이터 수집

일반적으로 데이터 세트 구성은 기계의 작동 상태에 따라 정상과 비정상 데이터를 수집하여 구성하는데, 본 논문에서는 공구의 여러 상태를 진단하기 위해 공작물을 절삭하지 않고 대기하고 있는 공회전 상태의 데이터도 수집한다. 공회전 시간은 공구가 재료에 구멍을 뚫거나 절삭하지 않고 계속 회전하는 순간을 나타내므로 정상적인 공구와 비정상 공구에 의해 생성되는 공회전 신호는 비슷하거나 같은 상태로 간주한다. 그림 2는 기계 작동 상태에서 (a) 공회전하고 있는 상태이고, (b) 알루미늄 공작물을 절삭하고 있는 상태이다.

정상과 비정상, 공회전 데이터 외에 절삭을 진행할 때 마모의 정도에 따라 또는 파손된 공구에서 생성되는 음향 신호까지 5가지 종류의 데이터를 수집하고 데이터 세트를 구성하였다.

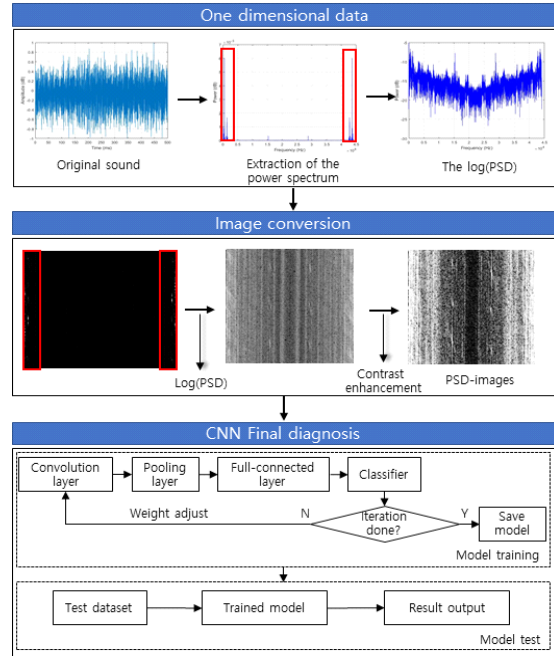


Fig. 1 The schematic representation of the proposed method




Fig. 2 Machine working condition

즉, 대기 상태에서 나오는 공회전과 초기 작동 단계인 건강한 공구에서 수집된 정상적인 데이터, 마모가 중간 정도 진행된 상태의 데이터, 작동 단계에서 결함이 있는 공구를 사용하여 수집된 비정상적인 데이터이다. 비정상적인 데이터는 마모가 많이 진행되어 제품에도 손상을 줄 수 있는 심각한 마모 상태와 공구날이 파손되어 사용할 수 없는 상태이다. 그림 3은 데이터 세트에서 랜덤하게 선택된 5가지 상태에 대한 음향 신호로 데이터 길이는

각 500ms 이다. 그림 3의 파형을 보면 알 수 있듯이 각 상태의 신호는 비슷한 결과를 보여준다(시각화를 위해 데이터는 모두 -1과 1사이에서 정규화 되었다). 원 시계열 데이터는 5가지 각각의 상태에 대해 데이터 간에 존재하는 고유한 차이점이 드러나지 않음을 알 수 있다.

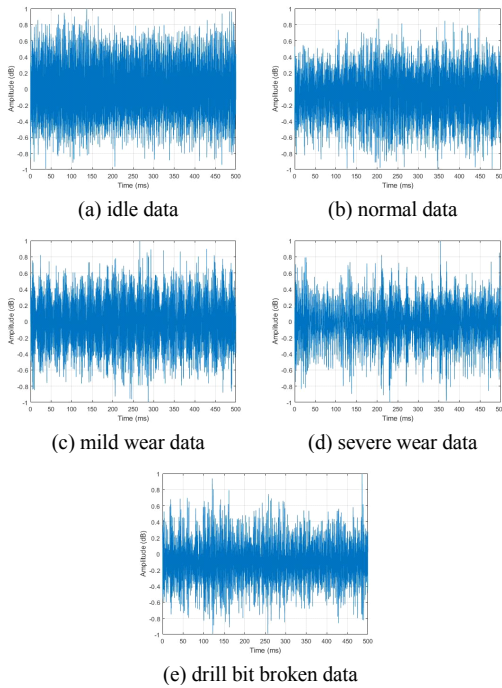


Fig. 3 Example of the data samples collected for the experiments, each data has a length of 500 milliseconds

3.2. PSD 영상 변환

주파수 기반의 전력스펙트럼밀도를 이용하여 영상으로 표현하기 위해, 먼저 1차원 음향 신호의 푸리에 계수를 이용하여 신호 전력인 전력스펙트럼밀도를 계산한다. 그런 다음 전력스펙트럼밀도를 이용하여 2차원 행렬 벡터로 만든 후 생성된 2차원 행렬을 8비트 그레이 영상으로 표현하도록 정규화 하는데, 식 (1)을 사용하여 정규화 한다.

$$I_{nor} = (I - Min) \frac{nMax - nMin}{Max - Min} + nMin \quad (1)$$

식 (1)은 정규화된 행렬의 값을 나타낸다. Max와 Min은 원 신호에서 추출된 스펙트럼 크기의 최대값과 최소값을 나타내고, nMax와 nMin은 각각 영상 변환을 위해

적용할 새로운 최대값과 최소값이다. 8비트 그레이 영상을 얻으려고 할 때, 새로운 nMax와 nMin 값은 255와 0으로 설정된다. 그림 4는 음향 신호에서 전력스펙트럼 밀도 구하고, PSD 벡터의 값을 균일하게 정규화하여 생성된 결과 영상이다.

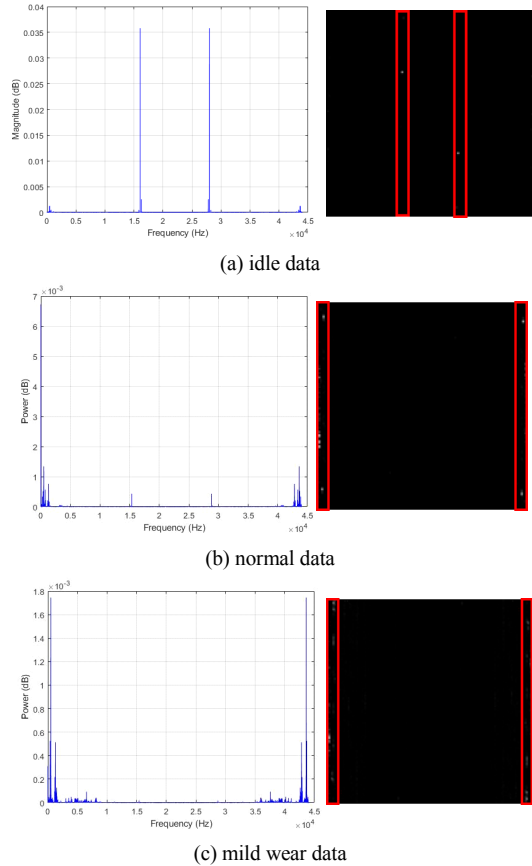


Fig. 4 Example of power spectrum density, and its 8bit normalized image

5가지 실험 데이터 중 공회전과 정상, 중간마모에 대한 결과를 보인 예로 대부분의 에너지는 저주파에 집중되어 있다. 저주파 대역은 그림 4의 빨간색으로 표시된 영역에서 볼 수 있듯이 이런 종류의 벡터를 2차원 행렬로 적용할 때 최대 에너지를 갖는 영역인 저주파 대역이 행렬의 두 말단에 위치할 것으로 예상된다. 또한 벡터에 있는 대부분의 구성 요소는 실제로 매우 작아 스펙트럼은 주로 검은색 픽셀로 구성되고, 피크에 해당하는 저주파 대역에 있는 부분만 흰색이 되는 경향이 있다. 그림 4

에서 보듯이 명암 대비가 매우 낮은 영상을 보여주고 있다. 벡터 내부의 이러한 큰 편차를 방지하고 영상의 공정한 대비를 제공하기 위해 다음과 같이 PSD의 대수적 로그를 적용한다.

그림 5는 5가지 상태별 전력스펙트럼밀도의 대수적 로그를 적용한 후 8비트 그레이 영상으로 변환한 결과이다. 대부분 어두운 픽셀을 포함하는 고주파는 영상의 중앙에 위치해 있고, 저주파는 영상의 양 끝에 위치해 있어 전력스펙트럼 에너지가 어떻게 분포되어 있는지를 알 수 있다. 본 연구에서 에너지가 최대인 영역이 실제로 데이터를 구별하기 위한 유용한 정보가 들어 있다고 본다. 따라서 공간적으로 이웃한 영역에 숨겨진 패턴을 영상 전체에 퍼뜨리기 위해 히스토그램 균등화를 사용하여 영상의 대비를 조정한다. 그 결과 대비가 강화된 영상이 가장자리가 상당히 날카로워져 고주파 성분이 증가하므로 마지막 단계는 가우시안 필터를 적용하여 영상을 부드럽게 한다.

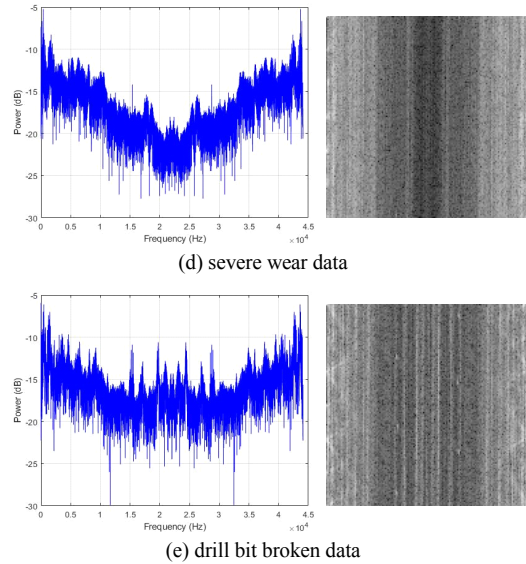
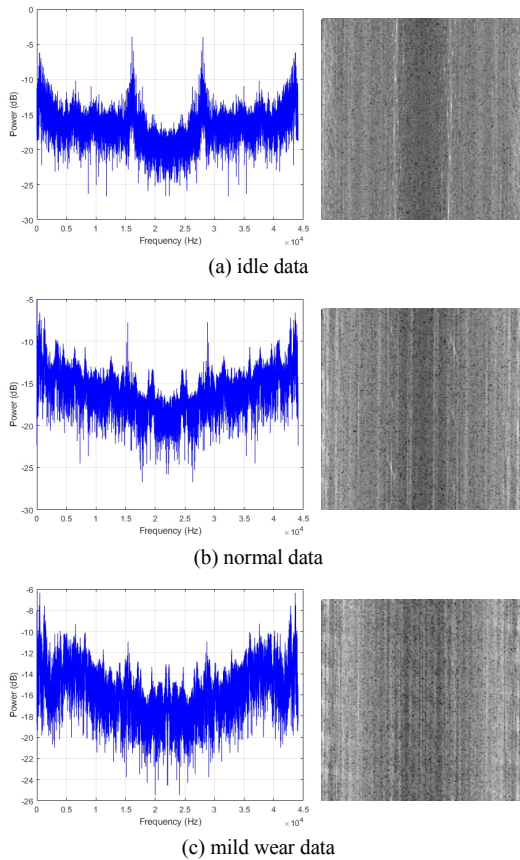


Fig. 5 Example of applying logarithmic scale representation of the power spectrum, and its resulting image

3.3. 공구 상태 진단을 위한 CNN 모델

CNN은 딥러닝에서 주로 영상 데이터를 처리할 때 쓰이며 이름에서 알 수 있듯이 Convolution이라는 전처리 작업이 들어가는 Neural Network 모델이다. CNN은 원 입력 데이터를 그대로 받음으로써 공간적/지역적 정보를 유지한 채 특징들의 계층을 빌드업 한다. CNN의 중요 포인트는 영상의 한 픽셀과 주변 픽셀들의 연관성을 살리는 것으로 숨겨진 패턴 즉, 유용한 데이터들의 연관성을 특징으로 잘 찾아내기 위함이다. CNN은 크게 컨볼루션 계층(convolutional layer)과 풀링 계층(pooling layer) 구성된다. 컨볼루션 계층은 입력데이터로부터 특징을 추출하는 역할하고, 특징을 추출하는 기능을 하는 필터(filter)와 이 필터의 값을 비선형 값으로 바꾸어 주는 활성화 함수(activation function)로 이루어진다. 풀링 계층은 비선형 다운 샘플링을 수행하여 크기를 줄여주는 층으로 연속적인 컨볼루션 계층 사이에 주기적으로 위치한다. 마지막으로 완전연결 계층(fully connected layer)은 softmax를 이용해 현재 공구의 상태를 분류한다. 본 논문에서는 경량 장비에서의 사용을 고려하여 2개의 컨볼루션 계층과 풀링 계층으로 구성하고, 분류기로 2개의 완전연결 계층을 사용한다. 마지막 완전연결 계층은 5가지 공구 상태를 구분하기 위해 뉴런의 개수를 5개로 설정하였다.

IV. 실험 결과 및 고찰

실험에 사용된 공구는 고속 스틸의 HSSCo8 절삭 드릴로 비트의 직경은 12 mm 이고, 1000 rpm의 회전속도로 5가지 상태의 데이터를 수집하였다. 그림 3에 표시된 데이터 샘플에서 신호 길이는 500 ms이고, 사용된 샘플링 주파수는 44.1 kHz이다. 즉, 모든 단일 데이터는 22,050개의 벡터를 가진다. 그리고 각 상태별 데이터 세트는 공회전 1,004, 정상 1,367, 중간 마모 1,228, 심각한 마모 951, 그리고 공구날이 파손된 상태 1,236 총 5,786 개 데이터 세트를 가진다.

다음으로 수집된 신호를 CNN을 이용해 한 번에 5가지의 상태를 진단하는데, 그림 4와 5에서 1차원 입력 신호를 2차원 PSD 영상으로 변환하는 방법을 보였다. 원본 데이터 매트릭스는 5,786×22,050 이고, 이를 통해 총 획득된 영상은 5,786×1482개 이다. 즉, PSD 입력 영상의 크기는 148×148이고 CNN의 입력으로 사용된다. 컨볼루션 계층과 맥스 풀링 계층이 쌓을 이루어 2번 반복하고, 2개의 완전 연결 계층을 이용해 5가지 공구 상태를 진단한다. 표 1은 실험에서 사용한 CNN 구조이다. 사용된 매개변수들은 반복적 실험에 의해 얻어진 것으로 ConvN은 N번째 convolutional layer, Max poolN은 N번째 maximum pooling layer, FC layerN은 N번째 fully connected layer를 말한다. FC layer1에서 10개의 뉴런을 추출하고, FC layer2에서 5개의 뉴런을 추출하여 최종적으로 공구 상태에 따라 진단한다.

실험은 Matlab을 이용하였으며, 그림 6은 confusion matrix로 총 5,786개의 데이터 중 학습에 70%, 테스트에 30%를 적용한 결과 99.6%의 매우 우수한 정확도를 보였다. 그림 3의 원 음향 신호에서 정상 상태와 비정상 상태, 공회전 상태에서 보인 신호들을 보면 상호 유사한 점이 존재하지만, PSD 영상을 통해 각 상태별 차별화된

Table. 1 Architecture of the CNN

Layer	Filter Size	#Filters	Stride	Padding	Output
Input	-	-	-	-	148×148
Conv1	11×11	16	1	0	138×138×16
Max pool1	2×2	-	2	0	69×69×16
Conv2	5×5	32	1	0	65×65×32
Max pool2	2×2	-	2	0	32×32×32
FC layer1	-	-	-	-	10
FC layer2	-	-	-	-	5

output class	Idle	300	0	0	0	0	Total Accuracy 99.6%
	Mild	0	368	0	0	0	
	Normal	0	0	410	1	0	
	Severe	1	0	0	284	5	
	Broken	0	0	0	0	366	
		99.7%	100%	100%	99.6%	98.7%	
	Idle	Mild	Normal	Severe	Broken	Target Class	

Fig. 6 Confusion matrix of the classification results

특징이 잘 반영되었다는 것을 분류의 결과로 알 수 있다.

실험에서 제시한 CNN 모델은 2개의 완전연결 계층을 사용한다. 첫 번째 완전연결 계층의 결과를 확인해 보기 위해 중간 결과를 가져와 주성분 분석을 사용하였다. 주성분 분석을 사용하면 데이터간의 관계를 이용해 시각화할 수 있다. 그림 7은 시각화한 결과를 보인 것으로, 첫 번째 연결 연결 계층에서 feature1 및 feature2, feature3는 각각 첫 번째 및 두 번째, 세 번째 주성분 축을 나타낸다. 3 가지 주성분을 투영한 결과로 각 상태별 특징들이 잘 반영되어 분류가 잘 된 것을 확인할 수 있다. 범주는 A: 공회전, B: 정상, C: 중간 마모, D: 심각한 마모, E: 공구날이 파손된 상태이다.

같은 방법으로 그림 8은 두 번째 완전연결 계층에서 세 번째까지의 주성분을 추출하여 투영한 결과로 그림 7과 비교하면, 두 번째 완전연결 계층은 최종 오류 판단을 위해 사용되므로 상태별 데이터의 특징이 더 잘 반영된 것을 알 수 있다.




Fig. 7 Visualization of the first three principal components from the first fully connected layer




Fig. 8 Visualization of the first three principal components from the second fully connected layer

표 2는 기존의 방법과 제안한 방법의 분류 정확도를 비교한 것이다. 다양한 센서를 이용해 얻은 데이터들과 동일한 종류의 신호에 대해 모두 설계되지 않았기 때문에 완벽한 비교 분석을 제공하는 것은 아니다. 딥러닝의 경우 매개변수들이 정확도에 많은 영향을 주기도 한다. 본 논문에서 비교 연구는 공구 상태 진단에 음향 PSD + CNN를 이용한 결과가 다른 방법과의 차별화된 특징을 반영했다는 것이다. [10]에서 사용된 이산 웨이블릿 변환(DWT)과 [14]에서 제안한 웨이블릿 패킷 계수(WC)는 시간-주파수 영역 기반 기능도 데이터의 특성을 파악하지만, 공구에서 생성된 음향 신호의 경우 제안한 방법이 좀 더 우수한 정확도를 보였다.

Table. 2 Results of the conventional and proposed method

	K.M. Lee et al.[10]	M. Zhao et al.[14]	Proposed Method
Method	DWT + PCA + ANN	WC+DRN	PSD images + CNN
accuracy	94.5%	96%	99.6%

V. 결론

본 논문에서 정밀 가공공정에서 발생하는 다양한 공구 상태를 진단하기 위해 공회전 및 정상, 중간 마모, 심각한 마모, 공구날이 파손된 5가지 공구 상태의 음향 신호를 수집하였다. 1차원 음향 신호의 전력스펙트럼 구성 요소를 추출하고, 영상으로 변환한 다음 대비 향상을

적용하고, 공간 필터링 마스크로 영상을 부드럽게 만들고, 이를 CNN의 입력으로 사용하는 새로운 특징 표현을 제안했다. 제안한 PSD 영상 + CNN은 유용한 데이터의 숨겨진 패턴을 발견하고, 특징을 잘 반영했음을 높은 정확도를 통해 알 수 있었다. 가공공정은 소재의 특성과 형상을 고려하여 인서트, 엔드밀, 비트 등 다양한 공구가 사용된다. 하지만, 본 논문에서는 각종 기계가 작동되고 있는 현장에서의 신호 수집의 애로사항이 있어 밀링 머신만 동작하는 환경에서 데이터를 수집하여 주변 장치간의 잡음에 대한 부분이 반영되지 않았다. 또한 생산 현장에서 다양한 센서를 통해 보다 많은 데이터 수집하고 분석해야할 필요가 있다. 향후 이를 통해 열악한 제조업 분야의 지능형 생산 공장 위한 공구의 상태를 진단하고 모니터링하는 일반화된 AI 공구관리 모델을 만드는데 지속적인 연구 개발이 요구된다.

References

- [1] H. D. Jeong, S. H. Kim, S. H. Woo, S. H. Kim, and S. C. Lee, "Real-Time Monitoring System for Rotating Machinery with IoT-based Cloud Platform," *Transactions of the Korean Society of Mechanical Engineers*, vol. 41, no. 6, pp. 517-524, Jun. 2017.
- [2] K. Patra, A. K. Jha, T. Szalay, J. Ranjan, and L. Monostori, "Artificial Neural Network Based Tool Condition Monitoring in Micro Mechanical Peck Drilling Using Thrust Force Signals," *Precision Engineering*, vol. 48, pp. 279-291, Apr. 2017.
- [3] B. H. Park, Y. J. Lee, and C. W. Lee, "Tool Condition Monitoring Using Deep Learning in Machining Process," *Journal of the Korean Society for Precision Engineering*, vol. 37, no. 6, pp. 415-420, Jun. 2020.
- [4] X. Yang, J. S. Lee, and H. K. Jung, "Fault Diagnosis Management Model using Machine Learning," *Journal of Information and Communication Convergence Engineering*, vol. 17, no. 2, pp. 128-134, Jun. 2019.
- [5] D. H. Kim, J. M. Lee, and J. D. Kim, "Design and Implementation of a Real-Time Product Defect Detection System based on Artificial Intelligence in the Press Process," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 25, no 9, pp. 1144-1151, Sep. 2021.
- [6] A. V. Atli, O. Urhan, S. Ertürk, and M. Sönmez, "A

- computer vision-based fast approach to drilling tool condition monitoring,” in *Proceedings of the Institution of Mechanical Engineers Part B Journal of Engineering Manufacture*, London, U.K, vol. 220, no. 9, pp. 1409-1415, Sep. 2006.
- [7] P. K. Kankar, S. C. Sharma, and S. P. Harsha, “Fault diagnosis of ball bearings using machine learning methods,” *Expert Systems with Applications*, vol. 38, no. 3, pp. 1876-1886, Mar. 2011.
- [8] M. Saimurugan and K. I. Ramachandran, “A comparative study of sounds and vibration signals in detection of rotating machine faults using support vector machine and independent component analysis,” *International Journal of Data Analysis Techniques and Strategies*, vol. 6, no. 2, pp. 188-204, Jun. 2014.
- [9] Y. S. Wang, Q. H. Ma, Q. Zhu, X. T. Liu, and L. H. Zhao, “An intelligent approach for engine fault diagnosis based on Hilbert-Huang transform and support vector machine,” *Applied Acoustics*, vol. 75, pp. 1-9, Jan. 2014.
- [10] K. -M. Lee, C. Vununu, K. -S. Moon, S. -H. Lee, and K. -R. Kwon, “Automatic Machine Fault Diagnosis System using Discrete Wavelet Transform and Machine Learning,” *Journal of Korea Multimedia Society*, vol. 20, no. 8, pp. 1299-1311, Aug. 2017.
- [11] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, pp. 436-444, May. 2015.
- [12] F. Jia, Y. Lei, J. Lin, X. Zhou, and N. Lu, “Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data,” *Mechanical Systems and Signal Processing*, vol. 72-73, pp. 303-315, May. 2016.
- [13] D. Verstraete, A. Ferrada, E. L. Drogue, V. Meruane, and M. Modarres, “Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings,” *Shock and Vibration*, vol. 2017, pp. 1-17, Oct. 2017.
- [14] M. Zhao, M. Kang, B. Tang, and M. Pecht, “Deep Residual Networks With Dynamically Weighted Wavelet Coefficients for Fault Diagnosis of Planetary Gearboxes,” *IEEE Transactions on Industrial Electronics*, vol. 65, no. 5, pp. 4290-4300, May. 2018.
- [15] C. Lu, Z. Wang, and B. Zhou, “Intelligent Fault Diagnosis of Rolling Bearing Using Hierarchical Convolutional Network based Health State Classification,” *Advanced Engineering Informatics*, vol. 32, pp. 139-151, Apr. 2017.
- [16] S. Guo, T. Yang, W. Gao, C. Zhang, and Y. Zhang, “An Intelligent Fault Diagnosis Method for Bearings with Variable Rotating Speed based on Pythagorean Spatial Pyramid Pooling CNN,” *Sensors*, vol. 18, no. 11, p. 3857, Nov. 2018.
- [17] W. Sun, R. Zhao, R. Yan, S. Shao, and X. Chen, “Convolutional Discriminative Feature Learning for Induction Motor Fault Diagnosis,” *IEEE Transactions on Industrial Informatics*, vol. 13, no. 3, pp. 1350-1359, Jun. 2017.



이경민(Kyeong-Min Lee)

2000년 : 동의대학교 컴퓨터공학과(공학사)
2002년 : 동아대학교 전자공학과(공학석사)
2019년 : 부경대학교 IT융합응용공학과(공학박사)
2010년~2020년 : 동명대학교 학부교양대학 초빙교수
2021년~ 현재 : 신라대학교 컴퓨터공학부 조교수
※관심분야 : 영상처리, 멀티미디어 신호처리, 머신러닝