

계층적 컨볼루션 신경망을 이용한 공작기계의 공구 상태 진단

이경민

신라대학교 컴퓨터공학부

Machine Tool State Monitoring Using Hierarchical Convolution Neural Network

Kyeong-Min Lee

Dept. of Computer Engineering, Silla University

요 약 공작기계 상태 진단은 기계의 상태를 자동으로 감지하는 프로세스이다. 실제로 가공의 효율과 제조공정에서 제품의 품질은 공구 상태에 영향을 받으며 마모 및 파손된 공구는 공정 성능에 보다 심각한 문제를 일으키고 제품의 품질 저하를 일으킬 수 있다. 따라서 적절한 시기에 공구가 교체될 수 있도록 공구 마모 진행 및 공정 중 파손 방지 시스템 개발이 필요하다. 본 논문에서는 공구의 적절한 교체 시기 등을 진단하기 위해 딥러닝 기반의 계층적 컨볼루션 신경망을 이용하여 5가지 공구 상태를 진단하는 방법을 제안한다. 기계가 공작물을 절삭할 때 발생하는 1차원 음향 신호를 주파수 기반의 전력스펙트럼밀도 2차원 영상으로 변환하여 컨볼루션 신경망의 입력으로 사용한다. 학습 모델은 계층적 3단계를 거쳐 5가지 공구 상태를 진단한다. 제안한 방법은 기존의 방법과 비교하여 높은 정확도를 보였고, 실시간 연동을 통해 다양한 공작기계를 모니터링할 수 있는 스마트팩토리 고장 진단 시스템에 활용할 수 있을 것이다.

• **주제어** : 공작기계 상태 진단, 딥러닝, 계층적 컨볼루션 신경망, 음향 신호, 전력스펙트럼밀도

Abstract Machine tool state monitoring is a process that automatically detects the states of machine. In the manufacturing process, the efficiency of machining and the quality of the product are affected by the condition of the tool. Wear and broken tools can cause more serious problems in process performance and lower product quality. Therefore, it is necessary to develop a system to prevent tool wear and damage during the process so that the tool can be replaced in a timely manner. This paper proposes a method for diagnosing five tool states using a deep learning-based hierarchical convolutional neural network to change tools at the right time. The one-dimensional acoustic signal generated when the machine cuts the workpiece is converted into a frequency-based power spectral density two-dimensional image and use as an input for a convolutional neural network. The learning model diagnoses five tool states through three hierarchical steps. The proposed method showed high accuracy compared to the conventional method. In addition, it will be able to be utilized in a smart factory fault diagnosis system that can monitor various machine tools through real-time connecting.

• **Key Words** : Machine Tool State Monitoring, Deep Learning, Hierarchical Convolution Neural Network, Acoustic Signal, Power Spectral Density

Received 15 June 2022, Revised 22 June 2022, Accepted 25 June 2022

* **Corresponding Author** Kyeong-Min Lee, Department of Computer Engineering, Silla University, Busan, 46958, Korea.
E-mail: kmlee2k@silla.ac.kr

I. 서론

4차 산업혁명은 산업 트렌드와 패러다임을 빠르게 변화시키면서 최근 제조업 분야에서도 이러한 변화에 적응하기 위해 AI 등을 활용한 다양한 스마트팩토리 플랫폼이 본격적으로 개발되고 있다. 제조업의 스마트 모니터링 기술은 생산에 영향을 주는 모든 시스템의 물리량을 센서로 수집하고 상태를 분석하는 것으로 품질 유지, 사고 예방, 고장 방지, 생산 시간 단축, 기계 수명 증가, 에너지 절약 등을 실현한다. 특히 모니터링 기술이 기계 가공 공정 분야에서 중요하다. 그 이유는 공구로 공작물을 절삭하는 중에 발생하는 공구 파손, 공구 마모, 채터(chatter) 등이 제품의 품질과 밀접한 관계를 맺고 있기 때문이다[1]. 따라서 절삭 중에 발생하는 센서의 신호를 분석하여 장비의 성능을 진단하고 [2] 고장 여부를 예측하는 스마트 시스템이 사용되기도 한다[3]. 또한 베어링 부품 수명 및 회전 효율 향상을 위한 기술로 공압 베어링[4-5], 유압 베어링, 자기 베어링[6] 등이 연구 개발되고 있다.

본 논문에서는 기계 가공 공정 분야 중 대표적인 밀링 머신의 공구 상태 진단에 초점을 맞춘다. 볼 베어링 요소, 기어 박스 및 샤프트와 같은 회전 기계의 결합 진단은 문헌에서 다양하게 연구되고 논의되었지만 밀링 머신의 공구 진단과 관련된 논문을 찾는 것은 쉽지 않다. 따라서 본 논문에서는 밀링머신에서 알루미늄 공작물을 깎으면서 발생하는 음향 신호를 이용하여 기계의 공구 상태를 진단하는데, 딥러닝 기반의 계층적 컨볼루션 신경망을 이용한다. 공구는 소재를 가공하면서 발생하는 절삭 저항과 마찰로 인해 마모되면서 소음이 발생하고, 이는 장치의 작동음에 반영된다. 장치의 작동음이나 진동을 분석하면 공구의 상태나 고장 발생 여부를 파악할 수 있다. 또한 입력 신호로 시간 영역[7-8]과 주파수 영역[9], 시간-주파수 영역 [10-11]에서의 1차원 신호를 이용한 연구가 많이 진행되고 있다. 본 논문에서는 1차원 음향 신호에서 특정 벡터를 효과적으로 추출하기 위해 주파수상의 전력스펙트럼밀도를 이용하고, 전력스펙트럼밀도 1차원 데이터를 2차원 영상으로 변환한다. 이는 특정 주파수 대역의 에너지를 이용하기보다 주요한 특성이 영상 전체에 잘 퍼지도록 전처리하여 그 데이터를 신경망 학습에 사용한다. 학습 모델은 계층적 3단계를 거쳐 5가지 공구 상태를 진단한다. 최종 결과 제안한 방법은 데이

터 간의 기존 차이점을 발견하여 데이터의 내부 특성을 포착할 수 있음을 보여준다. 기존의 통계적 기능은 이러한 차이점을 포착하지 못하고, [10]과 [11]에 제시된 시간-주파수 기반 기능도 데이터의 특성을 파악하지만, 공구에서 생성된 음향 신호의 경우 제안한 방법이 다소 우수한 진단 결과를 보였다. 그림 1은 제안하는 공작기계의 공구 상태 진단 방법을 블록도로 나타낸 것이다.

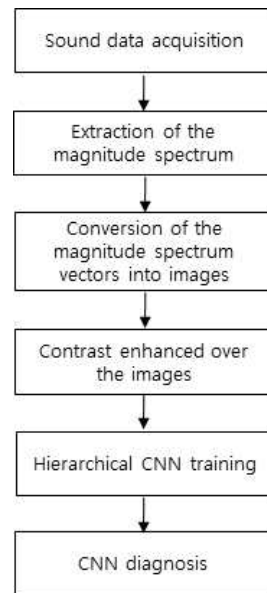


Fig. 1. Block diagram of proposed method

II. 연구방법

2.1 데이터 수집

일반적으로 데이터 세트 구성은 기계의 작동 상태에 따라 정상과 비정상 데이터를 수집하여 구성하는데, 본 논문에서는 공구 상태 진단을 위하여 다양한 작동 상태에서 생성된 데이터를 수집하였다. 공구가 공작물을 절삭하지 않고 대기하고 있는 공회전과 작동 중인 초기의 아주 정상적인 상태, 마모가 진행된 비정상 상태를 각각 수집했다. 이 작업에서 공회전은 재료에 구멍을 뚫거나 절삭하지 않고 계속 회전하는 순간을 나타낸다. 이 시간 동안 정상적인 공구와 마모된 공구에 의해 생성된 공회전 신호는 비슷하거나 같은 상태로 간주한다. 또한 앞서 언급한 3가지 종류의 데이터와

함께 절삭을 진행할 때 마모가 많이 진행된 비정상 데이터, 파손된 공구에서 생성되는 신호까지 총 5가지 종류의 데이터를 수집했다. 그림 2는 데이터를 수집한 공구의 상태를 보여준다. 마모가 중간 정도 진행된 상태와 제품에도 손상을 줄 수 있는 마모가 많이 진행된 상태, 비트가 파손된 공구 상태를 확인할 수 있다. 데이터는 공구마다 약 10분씩 수집하였고, 공회전은 모든 공구가 대기 상태일 때 각 2분씩, 총 8분의 데이터를 수집하였다.




Fig. 2. Condition of the tools used in the experiment


2.2 영상 변환

본 논문에서는 수집한 음향 신호의 1차원 데이터를 2차원 영상으로 표현하여 사용한다. 그 이유는 첫 번째로 컨볼루션 신경망을 이용하기 위한 것으로 영상의 고유한 특징을 부각시킨 특성 지도를 통해 영상의 특징과 영상 분류의 복잡성을 처리하는데 컨볼루션 신경망이 매우 우수한 성능이 보이기 때문이다. 두 번째는 어떤 특정 주파수가 아닌 전력스펙트럼밀도 영상 전체를 입력으로 사용함으로써, 데이터 사이의 동질성이 높여 진단의 정확성을 더 높일 수 있기 때문이다. 그림 3은 데이터 세트에서 랜덤하게 선택한 음향 신호와 그에 대한 전력스펙트럼밀도를 보인 것이다[12]. 그림에서 알 수 있듯이 음향 신호는 상태별 신호의 특징을 구별하기 어렵지만, 전력스펙트럼밀도는 특정 주파수 대역 또는 해당 주파수 영역의 크기 값을 비교하여 상태별 특징을 구별할 수 있다. 하지만, 본 논문에서는 사용자의 판단에 따른 어떤 특정 주파수 선택이 아닌 전력스펙트럼밀도 영상 전체를 컨볼루션 신경망의 입


력으로 사용하여 고유한 특징이 자동으로 학습되어 도출될 수 있도록 하였다.




(a) idle data




(b) normal data



(c) mild wear data



(d) severe wear data



(e) Drill bit broken data

Fig. 3. Example of the data samples collected for the experiment, and its the power spectrum


전력스펙트럼밀도 영상은 1차원 전력스펙트럼밀도 벡터를 2차원 행렬 벡터로 만든 후 8비트 그레이 영상으로 표현하도록 정규화한다. 전력스펙트럼밀도의 경

우 벡터 값이 매우 작아 그림 3에서 알 수 있듯이 정상 데이터에서 대략 3.5×10^{-3} 값을 가지고, 심한 마모의 경우 최대 4.5×10^{-3} 벡터 값을 가진다. 따라서 전체적으로 값이 매우 작고, 0에 가깝기 때문에 생성된 영상은 주로 검정색 픽셀로 구성된다.


그림 4는 1차원 정상 데이터가 신경망의 입력으로 사용되기 위해 2차원 영상으로 변환되는 과정을 보인 것이다.




(a) Power spectrum converted to image



(b) Log(power spectral density)



(c) Log image



(d) Contrast enhanced

Fig. 4. Example of image conversion of normal data

그림 4 (a)에서 전력스펙트럼밀도 영상의 경우 거의 검정색으로 이루어져 있지만, 영상의 양 끝부분에 흰색 픽셀값으로 보이는 부분이 있다. 이는 저주파 대역 중 저주파 대역으로 시스템 상태의 모든 세부 사항들이 포함된 중요한 정보를 담고 있다[12]. 그림 4 (b)는 너무 작은 벡터값을 전체적으로 조정하기 위해 전력스펙트럼밀도에서 대수적 로그를 취하고, 그림 4 (c)는 이를 다시 8비트 그레이 영상으로 나타낸 것이다. 그림 4 (a)와 비교했을 때 대수적 로그를 적용한 영상이 저주파 대역을 포함한 특징을 좀 더 잘 나타내고 있음을 알 수 있다. 저주파 대역의 숨겨진 데이터 특성이 전체 영상으로 골고루 퍼질 수 있도록 특징에 사용될 정보를 보강하고, 데이터의 동질성을 향상시키기 위해 그림 4 (d)와 같이 히스토그램 균일화를 적용한다. 마지막으로 만들어진 그림 4 (d)의 영상이 컨볼루션 신경망의 입력으로 사용된다.

2.3 계층적 컨볼루션 신경망 구조

기존의 패턴인식은 데이터에 대한 사전 지식을 가진 사람이 어떤 특성을 도출해야 분류에 도움이 될지를 인위적으로 판단하여 적용함으로써 불확실성과 편견에 영향을 받게 된다. 본 논문에서는 시각적 영상을 분석하는 데 주로 사용되며, 높은 수준의 학습 방법으로 특성 추출과 분류 신경망을 직렬로 연결한 구조를 가진 컨볼루션 신경망을 사용한다.

일반적으로 결함 진단이나 상태 진단에 가장 많이 사용되는 방법은 작동 상태에서 정상과 비정상 데이터를 이용하여 진단하는 것이다. 본 논문에서는 작동 상태와 쉬고 있는 대기 상태를 구분하고, 다시 작동 상

태에서 정상과 비정상을 구분한다. 마지막으로 비정상 상태의 공구를 다시 구분한다. 즉, 공구의 상태를 3개의 범주로 나누고 5가지 공구 상태를 계층적으로 진단한다. 먼저 절삭하지 않고 대기하고 있는 공회전 상태와 공작물을 절삭하거나 절삭하고 있는 작동 상태 크게 2가지로 나눈다. 다음으로 작동하고 있는 상태를 정상과 비정상으로 나눈다. 가장 일반적으로 기계 결함뿐만 아니라 상태 진단을 위해 많이 사용되고 있는 방법이다. 마지막으로 비정상 상태를 마모 정도와 파손 상태로 나눈다. 공구의 마모 정도는 중간 마모와 제품에 손상을 줄 수 있는 마모가 많이 진행된 상태이고, 파손은 비트가 파손된 공구 상태이다. 그림 5는 본 논문에서 사용한 계층적 컨볼루션 신경망 구조이다. 계층적으로 진단되어 나온 결과의 정확도가 3장의 연구 결과를 통해 매우 높음을 알 수 있다.

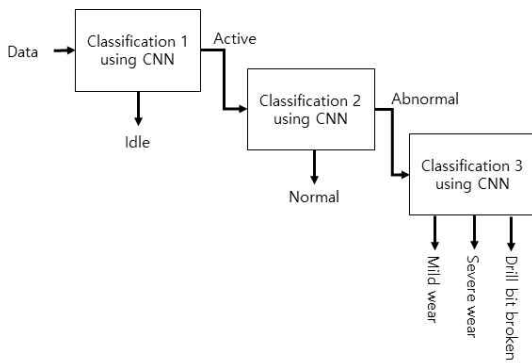


Fig. 5. Hierarchical convolutional neural network structure used in the experiment

III. 연구결과

실험에 사용된 공구는 고속 스틸의 HSSCo8 절삭 드릴로 비트의 직경은 12mm이고, 1,000rpm의 회전속도로 5가지 상태의 데이터를 수집하였다. 수집된 데이터는 주변 기계의 소음 등 원치 않는 정보 등이 포함되어 있어 신호 길이 500ms의 짧은 시간의 신호에도 2만 개가 넘는 벡터를 가지고 있다. 처리할 데이터의 크기가 클수록 분석이 더 복잡해질 수 있고, 영상으로 변환하여 사용할 때 영상 사이즈에 따라 학습시간이 많이 필요할 수 있다. 따라서 분석 중에 처리 시간을 최적화하고 데이터가 전달하는 정보의 관련성을 극대화하기 위해 실험에 사용된 샘플링 주파수는 44.1kHz이

고, 신호 길이 500ms로 22,050개의 벡터를 사용한다. 그리고 상태별 데이터 세트의 샘플 수는 공회전 1,004, 정상 1,367, 중간 마모 1,228, 심각한 마모 951, 그리고 공구 날이 파손된 데이터 1,236개로 총 5,786개 데이터 세트를 가진다. 다음으로 수집된 신호는 컨볼루션 신경망을 이용해 계층적으로 진단하는데, 그림 3과 4에서 1차원 입력 신호를 2차원 PSD 영상으로 변환하는 방법을 보였다. 원본 데이터 매트릭스는 5,786 × 22,050이고, 이를 통해 총 획득된 영상은 5,786 × 1482이다. 즉, 입력 영상의 크기는 148×148이고, PSD 영상에서 대수적 로그와 히스토그램 균일화 과정을 거쳐 CNN의 입력으로 사용된다. 컨볼루션 계층과 맥스 풀링 계층이 쌍을 이루어 2번 반복하고, 2개의 완전 연결 계층을 이용해 계층적으로 공구 상태를 진단한다. Adam optimizer를 사용해 학습하였고, 실험을 통해 얻어진 값으로 CNN 학습을 위한 주요 옵션은 표 1과 같다.

Table 1. Learning Options for CNN

Field	Value
Optimizer	adam optimizer
Mini-batch size	10
Shuffling	every-epoch
Epoch	10
Learning rate	0.001

실험은 Matlab을 이용하였으며, 데이터 세트에서 학습에 70%, 테스트에 30%를 적용하여 결과를 확인하였다. 그림 6은 첫 번째 계층적 진단으로 대기 상태와 작동 중인 2개의 상태를 진단한 것으로 정확도가 99.7%를 보였다.

그림 7은 작동 중인 상태의 정상과 비정상에 대한 진단으로 정확도가 99.6% 보였고, 그림 8은 비정상에 대한 상태로 중간 마모, 심각한 마모 및 공구 날이 파손된 마모를 진단한 것이다. 이 또한 정확도가 98.5%로 우수한 결과를 보였고, 전체 평균 99.3%로 상태별 신호들을 보면 상호 유사한 점이 존재하지만, 계층적 컨볼루션 신경망을 적용한 결과 공구의 상태를 거의 정확하게 진단함을 알 수 있다.

Output Class	Active	301	2	Total Accuracy 99.7%
	Idle	0	299	
		100%	99.3%	
		Active	Idle	
		Target Class		

Fig. 6. Idle state and active state

Output Class	Abnormal	407	0	Total Accuracy 99.6%
	Normal	3	410	
		99.2%	100%	
		Abnormal	Normal	
		Target Class		

Fig. 7. Normal state and abnormal state

Output Class	Drill bit broken	Mild	367	8	1	Total Accuracy 98.5%
		Severe	1	275	2	
	Mild	Severe	0	2	368	
		Drill bit broken	99.7%	96.5%	99.2%	
		Mild	Severe	Drill bit broken		
		Target Class				

Fig. 8. Abnormal state (mild wear, severe wear, drill bit broken)

Table 2. Result of the conventional and proposed method

	K.M. Lee et al.[10]	M. Zhao et al.[11]	Proposed Method
Method	DWT+PCA +ANN	WC+DRN	PSD images + Hierarchical CNN
accuracy	94.5%	96%	99.3%

IV. 고찰

본 논문에서 제안한 계층적 컨볼루션 신경망을 이용한 공작기계의 공구 상태 진단 기법은 기계가 작동 상태인지 대기 상태인지의 여부를 파악할 수 있고, 작동 상태일 경우 정상과 비정상의 여부도 알 수 있다. 또한 비정상의 경우 마모의 상태와 파손 상태까지 진단할 수 있다. 주파수 기반의 전력스펙트럼밀도를 이용해 2차원 영상으로 표현함으로써 각 공구의 차별화된 특징을 반영할 수 있는 방법을 제시하였고, 영상에서의 우수한 성능을 보이는 CNN을 이용하여 단계별 공구 상태의 높은 정확도를 확인할 수 있었다. 또한 기존의 방법과 비교하여 우수한 성능을 제시하였다. 가공공정은 다양한 종류의 공작 기계와 공구들이 사용되는데, 밀링머신에 한정되지 않고 진동 및 음향 방출 등 다양한 센서를 통한 데이터 축적으로 좀 더 일반화된 모델을 만들어 공작기계와 공구에 적용할 필요가 있다. 이는 지능형 스마트 팩토리의 기반이 될 것으로 향후 지속적인 연구 개발이 필요할 것이다.

표 2는 기존의 방법과 제안한 방법의 진단 정확도를 비교한 것이다. [10]에서 사용된 이산 웨이블릿 변환(DWT)과 [11]에서 제안한 웨이블릿 패킷 계수(WC)는 시간-주파수 영역 기반 분석을 이용한 것으로 공구에서 생성된 음향 신호의 경우 제안한 방법이 좀 더 우수한 정확도를 보인다.

REFERENCES

- [1] Y. J. An and J. Y. Kim, "A Study on Real-time Tool Breakage Monitoring on CNC Lathe Using Fusion Sensor," *Tribology and Lubricants*, vol. 28, no. 3, pp. 130-135, 2012.
- [2] J. H. Kim, J. S. Yoon, and D. Y. Lee, "Estimation of Tangential Cutting Force using Spindle Load of CNC Machining Center," *Journal of the Korean Society of Manufacturing Technology Engineers*, vol. 28 no. 6, pp. 343-349, 2019.
- [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, 2020.
- [4] D. Y. Lee and S. J. Yun, "Development of Deburring Spindle up to 80,000 rpm for Precision Finishing," *Korean Society for Precision Engineering Conference*, pp. 441-442, 2017.
- [5] I. S. Yook, D. H. Lee, G. S. Han, W. K. Han, and J. H. Hwang, "Development of the Air Bearing Spindle for Precision Machining for Metal case of the Smart-phone," *Korean Society for Precision Engineering Conference*, pp. 280-281, 2016.
- [6] C. H. Park and T. G. Yoon, "Development of Drilling Spindle for Micro-hole Machining with Magnetic Bearings," *Transactions of the Korean Society for Noise and Vibration Engineering*, vol. 27, no. 4, pp. 510-517, 2017.
- [7] M. Saimurugan and K.I. Ramachandran, "Detection The Behavior of Smartphone Users using Time-division Feature Fusion Convolutional Neural Network," *Journal of The Korean Institute of Information and Communication Engineering*, vol. 24, no. 9, pp. 1224-1230, 2020.
- [8] S. J. Yoon, M. Y. Lee, J. H. Lee, S. H. Lee, and J. C. Na, "Fault Diagnosis Using Artificial Intelligence for the Spindle of Machine Tools," *Transactions of the Korean Society of Mechanical Engineers*, vol. 45, no. 5, pp. 401-408, 2021.
- [9] J. Shi, G. Si, S. Li, B. Oresanya, and Y. Zhang, "Feature extraction based on the fractional Fourier transform for vibration signals with application to measuring the load of a tumbling mill," *Control Engineering Practice*, vol. 84, pp. 238-246, 2019.
- [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, 2017.
- [11] 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, issue 5, pp. 4290-4300, 2018.
- [12] K. M. Lee, "A Machine Fault Diagnosis System based on Convolution Neural Network using Acoustic Power Spectral Density," Ph. D. dissertation, Pukyong National University, Busan, Republic of Korea, 2019.

 저자소개

이 경 민 (Kyeong-Min Lee)



2000년 2월 : 동의대학교
컴퓨터공학과(공학사)
2002년 2월 : 동아대학교
전자공학과(공학석사)
2019년 2월 : 부경대학교
IT융합응용공학과(공학박사)
2010년~2020년 : 동명대학교
학부교양대학 초빙교수

2021년 ~ 현재 : 신라대학교 컴퓨터공학부 조교수
관심분야 : 영상처리, 멀티미디어 신호처리, 머신러닝