

다중 패턴 인식 기법을 이용한 DWT 전력 스펙트럼 밀도 기반 기계 고장 진단 기법

강경원[†], 이경민^{**}, 칼렙^{***}, 권기룡^{****}

Machine Fault Diagnosis Method based on DWT Power Spectral Density using Multi Patten Recognition

Kyung-Won Kang[†], Kyeong-Min Lee^{**}, Caleb Vununu^{***}, Ki-Ryong Kwon^{****}

ABSTRACT

The goal of the sound-based mechanical fault diagnosis technique is to automatically find abnormal signals in the machine using acoustic emission. Conventional methods of using mathematical models have been found to be inaccurate due to the complexity of industrial mechanical systems and the existence of nonlinear factors such as noise. Therefore, any fault diagnosis issue can be treated as a pattern recognition problem. We propose an automatic fault diagnosis method using discrete wavelet transform and power spectrum density using multi pattern recognition. First, we perform DWT-based filtering analysis for noise cancelling and effective feature extraction. Next, the power spectral density(PSD) is performed on each subband of the DWT in order to effectively extract feature vectors of sound. Finally, each PSD data is extracted with the features of the classifier using multi pattern recognition. The results show that the proposed method can not only be used effectively to detect faults as well as apply to various automatic diagnosis system based on sound.

Key words: Atificial Neural Network, Discrete Wavelet Transform, Machine Fault Diagnosis, Machine Learning, Pattern Recognition

1. 서 론

기계 시스템이 비정상적인 상태에서 지속적으로 동작할 경우 경제적 손실과 안전 문제를 초래할 수

있기 때문에 기계 시스템의 정상적인 상태를 유지하기 위해서는 기계 고장 진단 시스템이 필요하다. 일반적인 마모에 의해 야기되는 고장을 위한 기계 고장 진단 시스템은 공구와 소재가 맞는 곳에서 발생하

※ Corresponding Author : Ki-Ryong Kwon, Address: (48547) Yongso-ro, Nam-Gu, Korea, TEL : +82-51-629-6257, FAX : +82-51-629-6230, E-mail : krkwon@pknu.ac.kr
Receipt date : July 3, 2019, Revision date : Oct. 10, 2019
Approval date : Oct. 23, 2019

[†] Dept. of Information and Communications Eng., Tongmyong University
(E-mail : kangkw@tu.ac.kr)

^{**} College of General Education, Tongmyong University
(E-mail : kmlee2k@tu.ac.kr)

^{***} Dept. of IT Convergence and Application Eng., Pukyong National University
(E-mail : exen.xmen@gmail.com)

^{****} Dept. of IT Convergence and Application Eng., Pukyong National University

※ This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Science and ICT (NRF-2017R1A2B2012456) and the Ministry of Trade, Industry and Energy for its financial support of the project titled "the establishment of advanced marine industry open laboratory and development of realistic convergence contents, and MSIT (Ministry of Science and ICT), Korea, under the Grand Information Technology Research Center support program (IITP-2019-2016-0-00318) supervised by the IITP (Institute for Information & communications Technology Promotion)".

는 물리적인 현상을 센서를 활용해 데이터를 수집하고 수집된 정보를 통해 고장 여부를 분석하는 방법으로, 이 분야에 관한 연구들은 오래전부터 많이 진행되고 있다[1,2]. 특히 밀링머신과 관련된 기계 고장 진단 시스템은 공구의 마모 상태를 실시간으로 감지하거나 선행 실험을 통해 학습된 데이터를 바탕으로 공구마모 시점을 예측하는 것에 초점을 맞추고 있다. 공구의 마모나 파손을 감지하거나 발생 시점을 예측하는 것은 공정의 문제 발생과 제품의 품질 저하를 방지할 수 있을 뿐만 아니라 효율적인 공정 운영을 가능하게 한다.

지난 수십 년 동안 산업 프로세스에 대한 수학적 모델 기반 접근법을 통해 기계 고장 조건을 판단하는 방법에 관한 연구가 많이 진행되었다[3-5]. 그러나 실제 시스템의 복잡성과 원하지 않는 잡음과 같은 비선형적인 요인에 의해 수학적 모델 기반 접근법은 정확성면에서 효과적이지 않다. 따라서 기계 고장 진단을 체계적으로 수행하기 위해 기계학습 기반 접근법이 요구된다.

이 방법은 훈련 또는 학습이라는 과정을 통해 축적된 데이터를 해석하는 기법으로 인공신경망(Artificial neural network, ANN), 퍼지 논리(Fuzzy logic) 및 지원 벡터 시스템 등이 있다. 인공신경망은 역전파 알고리즘을 통해 복잡한 비선형 프로세스에 대해서 강력한 적응 학습 기능을 제공하기 때문에 결함 진단 응용에 널리 사용되고 있는 데이터 해석 기법이다[6]. 퍼지 논리는 신경망 알고리즘과 통합되어 진단 성능을 향상시킬 수 있는 데이터 해석 기법이다[7]. 신경망의 경우 연결망에 의해 지식이 암시적으로 표현되나 퍼지 논리는 퍼지 클래스와 퍼지 규칙을 사용하여 지식이 직설적인 언어적 방법으로 표현될 수 있기 때문에 결함 진단 분야에서 연구되고 있다. 그리고 지원 벡터 시스템은 신경망에 비해 간결하면서 뛰어난 데이터를 분류 성능을 보여주는 기계학습 방법이다[8]. 기계 고장 진단을 위한 훈련 또는 학습을 위한 데이터는 시간, 주파수 또는 시간-주파수 영역에서 측정된 신호로부터 특징을 추출될 수 있다.

시간 영역 기반의 특징 추출 방법은 시계열 데이터의 통계적 특징 추출에 초점을 맞추고 있다[9]. 주파수 영역 기반의 특징 추출 방법은 고속 푸리에 변환에 의한 스펙트럼 분석이 널리 사용되는 방법이다[10]. 또한 시간-주파수 영역기반의 특징 추출 방법

은 단시간 푸리에 변환(Short time fourier transform)과 이산 웨이블릿 변환(Discrete wavelet transform, DWT)을 활용한 분석이 사용된다[11].

본 논문에서는 효과적인 고장 진단을 위해 시간-주파수 영역기반에의 학습데이터와 다수의 인공신경망을 활용한 다중 패턴 인식 기법을 이용한 DWT 전력 스펙트럼 밀도 기반 기계 고장 진단 기법을 제안한다. 제안한 방법은 DWT 영역에서 스펙트럼 크기 기반에서 최적의 특징 벡터를 추출을 위한 다중 패턴 인식 기법이다. 데이터는 정상 공구와 마모가 많이 진행된 공구를 이용하여 공회전 상태와 동작 상태에서 생성된다. 먼저 이산 웨이블릿 변환을 통해 각 데이터가 가지고 있는 차이점을 최대화할 뿐만 아니라 중복 데이터를 제거한다. 그리고 푸리에 분석을 사용하여 각 데이터의 파워 스펙트럼 밀도의 크기를 계산한 후 각 데이터가 가지고 있는 특징 벡터를 추출하기 위해 다중 패턴 인식 분류기를 사용하여 시스템을 최종 진단한다. 결과적으로 제안한 특징 벡터 검출 방법은 기존의 특징과 달리 도구에서 생성된 소리의 숨겨진 패턴 정확하게 포착할 수 있다.

2. 인공신경망(ANN) 모델

인공신경망은 인간의 뉴런(Neuron)의 동작 원리에 기초해 인공적으로 구현한 것으로 신경 세포의 정보처리 및 전달과정과 유사하다. 인공신경망에서 가장 많이 사용되는 방식은 다층 퍼셉트론 신경망으로, Fig. 1과 같이 입력층, 출력층 및 하나 이상의 은닉층으로 구성된다. 이는 Fig. 1과 같이 사람의 신경망을 단순화한 형태로서 여러 가지 입력 데이터를 연결된 뉴런의 가중치와 곱한 후 합한 결과를 활성화 함수를 거쳐 다음 노드에 전달하는 방식으로 미지의




Fig. 1. Structure of neural networks.

시스템이 비선형성을 포함하여도 추정이 가능하게 된다. 이러한 과정은 식 (1)과 같이 근사방적으로 표현이 된다.

$$y_k = f\left(\sum_{j=1}^m w_{jk}^{(2)} g\left(\sum_{i=1}^n w_{ij}^{(1)} x_i + b_j\right) + b_k\right), \quad k=1, \dots, o \quad (1)$$

여기서, y_k 는 주어진 뉴런의 출력을 나타내며, n 은 입력 샘플의 수, m 은 은닉층의 수를 의미한다. 각 뉴런은 가중치를 가지고 연결되어 있기 때문에 반복

적인 조정학습을 수행하면 역전파(back propagation) 방법에 의해 식 (1)의 결과 값과 최종 목표 출력 값의 오차가 최소화되도록 가중치들이 조정된다.

3. 제안한 고장진단 방법

본 논문에서는 밀링머신이 소재를 가공할 때 공구에서 발생하는 소리를 이용하여 밀링머신의 고장을 진단하는 기법을 제안한다. 일반적으로 소리 데이터

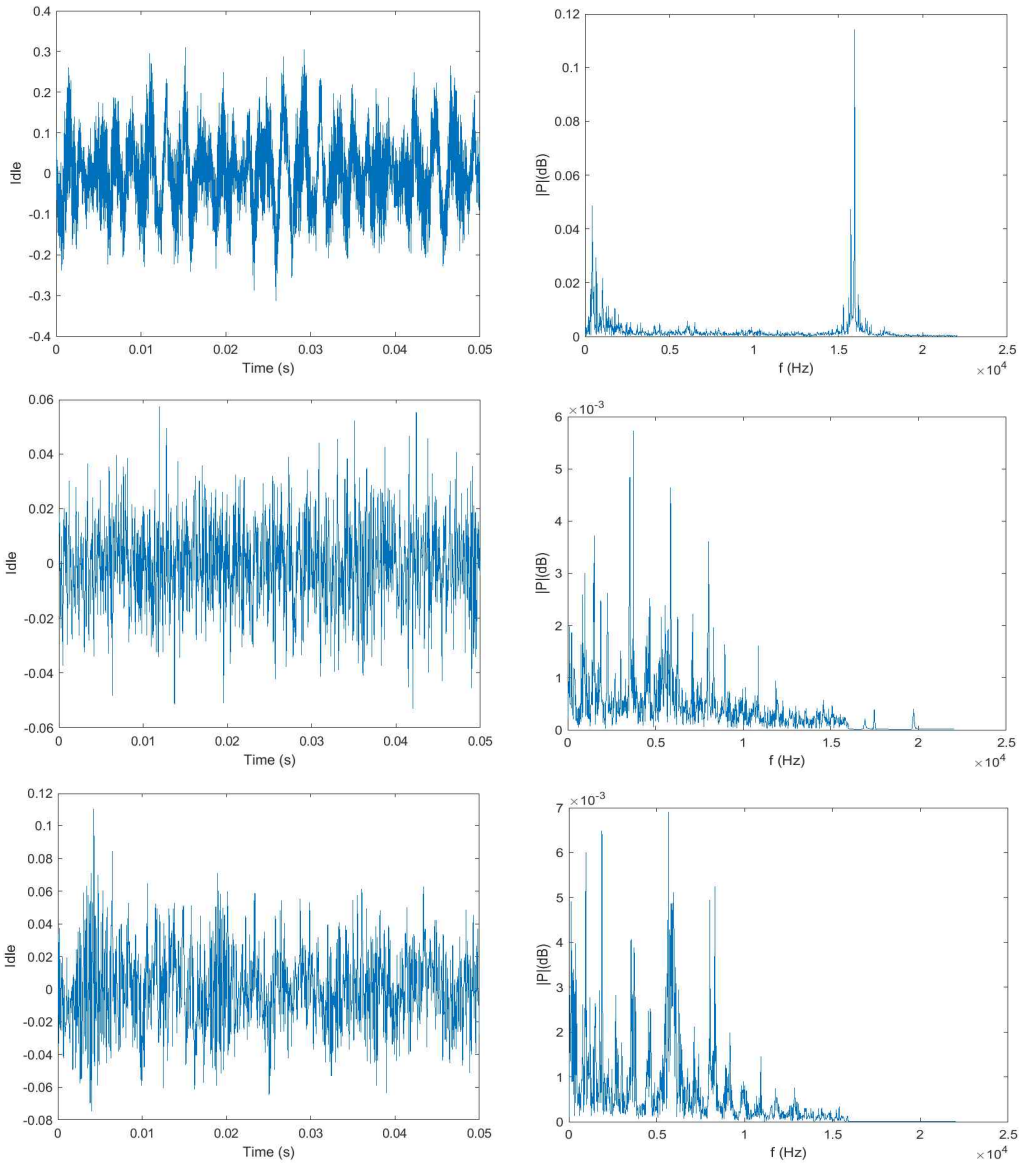


Fig. 2. Sound signals and their corresponding average power spectral density: (a) idle sound data, (b) normal sound data, (c) abnormal sound.




Fig. 3. Frequency subband representation of the 2-level DWT.

는 주변 잡음에 영향을 많이 받기 때문에 신호의 잡음에 강인한 방법이 필요하다. 실험을 위한 데이터는 제조공정에서 핸드 드릴을 이용해 공구의 공회전 시 발생하는 신호와 정상상태의 공구와 마모된 비정상상태의 핸드 드릴을 이용해 강철판을 깎을 때 생성된 신호를 AE(Acoustic Emission) 센서로부터 획득한 데이터이다. 신호의 샘플링 주파수는 44.1 kHz이며, 처리를 위한 신호의 길이는 50 ms이다.

AE 센서로부터 획득한 데이터의 시간영역 특성

과 주파수 영역 특성을 파악하기 위해 각각의 상태별로 1000개의 샘플링된 데이터에 대한 시간영역에서의 파형과 전력스펙트럼 밀도(Power spectral density, PSD)를 구하였다. Fig. 2는 임의의 시점에서의 시간영역에서의 파형과 PSD를 나타낸 것이다. PSD에서 특징 벡터를 추출할 경우 샘플링된 시간영역과 무관하게 특징을 추출할 수 있다. Fig. 2(a)는 공구가 임의의 시점에서 공회전상태의 신호를 나타낸 것이며, Fig. 2(b)와 Fig. 2(c)는 임의의 시점에서 정상상태의 공구와 마모된 비정상상태의 공구에 의해 야기된 신호를 나타낸 것이다. 시간영역의 신호들은 샘플링 시점에 따라 복잡한 형태로 표현되기 때문에 일관성 있는 특징을 추출하기가 어려우나 PSD 영역에서는 각각의 상태별로 고유 특징을 보여준다. Fig. 2(a)의 공회전상태인 경우 대략 16 kHz 부근에서 특징




Fig. 4. Average power spectral density of idle sound: (a) subband cD_2 of DWT, (b) subband cA_2 of DWT.




Fig. 5. Average power spectral density of normal sound: (a) subband cD_2 of DWT, (b) subband cA_2 of DWT.




Fig. 6. Average power spectral density of abnormal sound: (a) subband cD_2 of DWT, (b) subband cA_2 of DWT.

신호가 존재함을 알 수 있으며, 정상상태의 공구와 마모된 비정상상태의 공구의 경우 대부분의 특징이 저주파 영역에 집중되어 있는 특징 있다. 따라서 효과적으로 상태별 주파수 대역을 추출하기 위해 본 논문에서 DWT 기반 PSD 영역에서의 특징 추출을 제안한다.

Fig. 3은 2레벨 DWT 분해에 따른 주파수 부대역을 나타낸 것이다. 주파수 부대역은 분해 레벨에 따라 1/2씩 감소가 되기 때문에 레벨 1의 고주파 부대역(cD_1)은 22.05 kHz~44.1 kHz 영역으로 잡음이 포함될 수 있는 부대역이며, 레벨 2의 저주파 부대역(cA_2)은 0~11.025 kHz 영역으로 대부분의 특징 정보가 포함된 영역이다. 그리고 레벨 2의 고주파 부대역(cD_2)은 11.025 kHz~22.05 kHz로 공회전상태에서 발생하는 특징 신호가 포함된 영역이다. 따라서 공회전상태 신호의 특징 벡터를 검출하기 위한 대역은 cD_2 영역이 사용되며, 정상신호와 비정상신호의 특징 벡터를 검출하기 위한 대역은 cA_2 영역이 사용된다.

공회전상태 신호의 DWT기반 주파수 영역 특성 추출을 위해 1000개의 샘플링된 DWT 레벨 2의 고주파 부대역(cD_2)과 저주파 부대역(cA_2) 신호에 대한 PSD 신호를 Fig. 4에 보여준다. 특히 Fig. 4(a)에서는 시간영역에 대한 PSD에서와 동일하게 DWT 기반 PSD에서도 16 kHz 대역에 해당되는 레벨 2의 고주파 부대역(cD_2) 내에 특징 신호가 존재함을 제시하였다. 정상상태의 공구와 마모된 비정상상태의 공구신호에 대한 DWT의 고주파 부대역(cD_2)과 저주파 부대역(cA_2) 신호에 대한 1000개의 샘플링된 신호에

대한 PSD 신호는 Fig. 5와 Fig. 6에 제시하였다.

Fig. 7은 제안한 방법의 흐름도를 나타낸 것이다. 각각의 상태별 특징 벡터에 대한 효과적인 학습을 위해 다중 데이터셋으로 구성된 로지스틱 회귀(logistic regression)방식의 다중 패턴 인식 ANN으로 구성하였다. 공회전상태 신호 여부를 위해 레벨 2의 고주파 부대역(cD_2)에 대한 PSD으로 구성된 데이터셋을 학습하였으며, 정상신호 여부 및 비정상신호 여부를 위해 레벨 2의 저주파 부대역(cA_2)에 대한 PSD으로 구성된 데이터셋을 학습하였다.

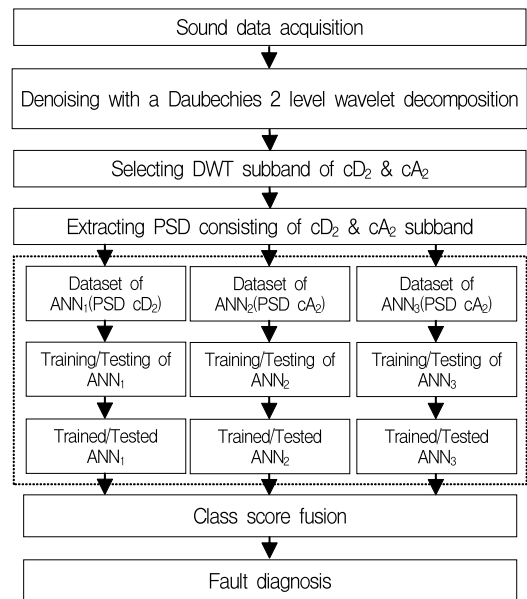


Fig. 7. Flowchart of the proposed method.

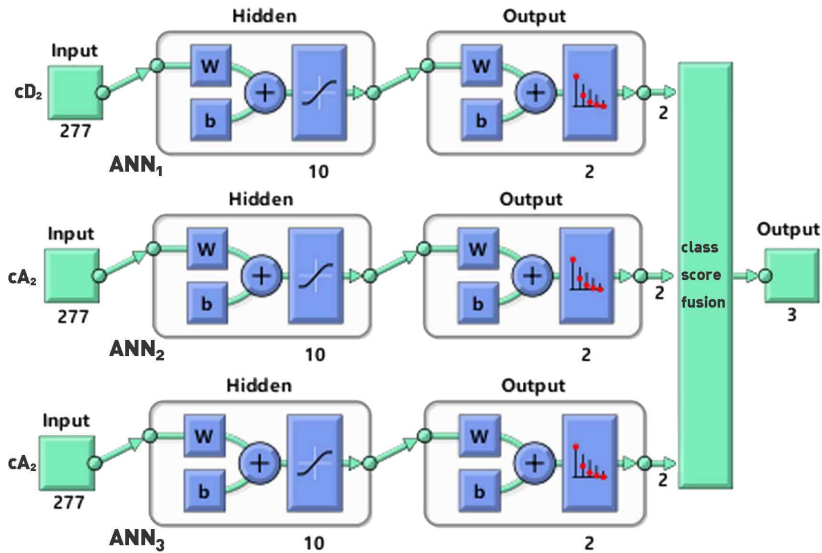


Fig. 8. Our network: 3×277 inputs neurons, 10 Hidden neurons and 3 Output neurons.

4. 실험 결과 및 고찰

본 실험에서는 마이크를 사용하여 밀링머신의 공회전상태에서 생성된 소리와 정상상태의 공구와 마모된 비정상상태의 공구를 사용하여 강철판을 깎을 때 생성된 소리를 각각 50 ms 씩 수집하였다. 수집된 소리 데이터의 샘플링 주파수는 44.1 kHz이며, 각각 상태별 1,000개의 데이터로 구성된 총 3000개의 데이

터셋에 대한 다중 인공신경망을 이용한 패턴 인식을 수행하였다. 인공신경망의 입력 데이터는 각각 수집한 데이터를 2레벨 DWT 분해 후 고주파 부대역(cD₂)와 저주파 부대역(cA₂)에 대한 PSD를 사용하였으며, 10개의 은닉 뉴런과 마지막 3개의 뉴런(공회전, 정상, 비정상)으로 구성하였다.

Fig. 8은 본 논문에서 적용된 인공신경망 네트워크는 나타낸 것이다. cD₂ 계수와 cA₂ 계수로 구성된

Confusion Matrix

Output Class	1	2000 66.7%	0 0.0%	100% 0.0%
	2	0 0.0%	1000 33.3%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%
		1	2	
		Target Class		

Fig. 9. Confusion matrix of ANN₁ (class 1: not idle, class 2: idle).

Confusion Matrix

Output Class	1	1999 66.6%	1 0.0%	100.0% 0.0%
	2	1 0.0%	999 33.3%	99.9% 0.1%
		100.0% 0.0%	99.9% 0.1%	99.9% 0.1%
		1	2	
		Target Class		

Fig. 10. Confusion matrix of ANN₂ (class 1: not normally, class 2: normal).




Fig. 11. Confusion matrix of ANN₃ (class 1: not abnormal, class 2: abnormal).

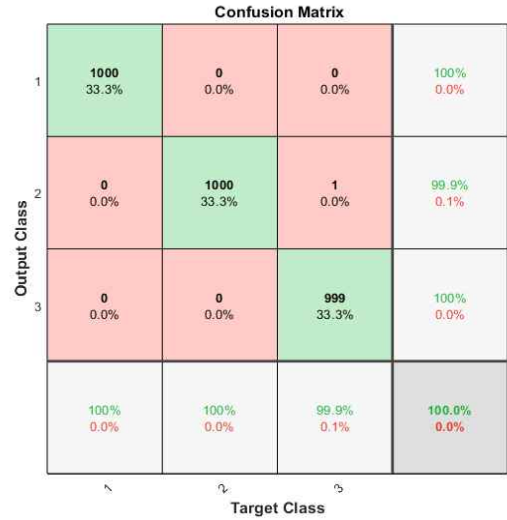


Fig. 12. Confusion matrix of all dataset (class 1: idle class 2: normal, class 3 : abnormal)

입력 특징 벡터의 수는 831개로 구성하였으며, 훈련셋(training set)과 시험셋(test set)의 비율은 7:3으로 구성하였다.

Fig. 9는 공회전상태의 신호 여부를 학습하기 위해 각 상태별 1,000 개로 구성된 총 3000개의 데이터셋에 대해 ANN₁의 분류 정확도를 나타낸 것이다. Class 2는 공회전상태의 신호임을 의미하며, Class 1은 그렇지 않음을 의미한다. 공회전상태 신호의 경우 특징 주파수가 존재하기 때문에 100% 분류 정확도를 나타내어 우수한 분류 능력을 보임을 확인하였다. Fig. 10과 Fig. 11은 정상상태의 공구와 마모된 비정상상태의 공구에 의해 야기된 신호 여부를 학습하기 위해 동일한 3000개의 데이터셋에 대해 ANN₂와 ANN₃의 분류 정확도를 나타낸 것이다. 각각의 Class 2는 검출하기 위한 상태의 신호임을 의미하며, Class 1은 그렇지 않은 신호를 의미한다. 실험 결과 정상상태의 공구와 마모된 비정상상태의 공구에 의해 야기된 신호의 경우 상호 유사한 점이 있어 각각 99.9%와 99.6% 분류 정확도를 나타내었다. 최종 출

력은 각각의 인공지능망 네트워크의 출력값 들의 평균을 활용한 융합 과정(class score fusion)을 통해 Fig. 12와 같이 다중 패턴 인식을 이용한 인공 신경망 네트워크에 의해 99.9% 분류 정확도를 얻을 수 있었다. 여기서 Class 1은 공회전상태의 신호를 의미하며, Class 2와 Class 3는 정상상태의 공구와 마모된 비정상상태의 공구에 의해 야기된 신호를 의미한다.

Table 1은 기존의 방법과 제안한 방법의 분류 정확도를 비교한 것으로 제안한 방법의 우수성을 확인할 수 있었다.

5. 결론

본 논문에서 제안한 다중 패턴 인식 기법을 이용한 DWT 전력 스펙트럼 밀도 기반 기계 고장 진단 기법은 소리를 이용한 패턴 인식 기반 공구의 결함 진단 영역에서 우수한 성능을 제시하였다. 소리의 특징 벡터를 효과적으로 추출하기 위해 DWT를 이용해 대역별로 부대역으로 분해한 후 특정 부대역에

Table 1. Summary of the result of the conventional and proposed method

	P.K. Kankar et al.[9]	K.Y. Lee et al.[11]	Proposed Method
Feature Extraction Method	Time serial + statistical features	Subband cA ₂ of DWT + PCA	Subband cD ₂ & cA ₂ of DWT + PSD
Classifier	Single-ANN	Single-ANN	Multi-ANN
Accuracy	64.20%	94.52%	99.97%

대해서 PSD 구하였다. PSD에서 특징 벡터를 추출할 경우 샘플링된 시간영역과 무관하게 특징을 추출할 수 있다. 또한 최상위 고주파 부대역 부분을 제외함으로써 주변 잡음에 강인한 특성을 얻을 수 있었으며, 다중 패턴 인식을 이용함으로써 분류 정확도 향상을 얻을 수 있었다. 제시한 방법은 다른 고장 진단 시스템에서 사용될 수 있으며, 공구의 정상 및 비정상적인 마모된 소리를 분리할 수 있으면 진동 및 기타 음향 방출 데이터에도 활용할 수 있을 것이다.

REFERENCE

- [1] G. Byrne, D. Dornfeld, I. Inasaki, G. Ketterler, W. Konig, and R. Teti, "Tool Condition Monitoring(TCM)-The Status of Research and Industrial Application," *International Institution for Production Engineering Research Annals*, Vol. 44, Issue 2, pp. 541-567, 1995.
- [2] R. Teti, K. Jemielniak, G. O'Donnell, and D. Dornfeld, "Advanced Monitoring of Machining Operation," *International Institution for Production Engineering Research Annals*, Vol. 59, Issue 2, pp. 717-739, 2010.
- [3] M.M. Polycarpou and A.T. Vemuri, "Learning Methodology for Failure Detection and Accommodation," *IEEE Control Systems Magazine*, Vol. 15, Issue 3, pp. 16-24, 1995.
- [4] K. Kumamaru, J. Hu, K. Inoue, and T. Soderstrom, "Robust Fault Detection Using Index of Kullback Discrimination Information," *International Federation of Automatic Control*, Vol. 29, Issue 1, pp. 6524-6529, 1996.
- [5] S. Takata, J.H. Ahn, M. Miki, Y. Miyao, and T. Sata, "A Sound Monitoring System for Fault Detection of Machine and Machining States," *International Institution for Production Engineering Research Annals*, Vol. 35, Issue 1, pp. 289-292, 1986.
- [6] Y. Maki and K.A. Loparo, "A Neural-network Approach to Fault Detection and Diagnosis in Industrial Processes," *IEEE Transactions on Control Systems Technology*, Vol. 5, Issue 6, pp. 529-541, 1997.
- [7] C. Chen, B. Zhang, G. Vachtsevanos, and M. Orchard, "Machine Condition Prediction Based on Adaptive Neuro-fuzzy and High-order Particle Filtering," *IEEE Transactions on Industrial Electronics*, Vol. 58, Issue 9, pp. 4353-4364, 2011.
- [8] Y.S. Wang, Q.H. Ma, Q. Zhu, and L. Zhao, "An Intelligent Approach for Engine Fault Diagnosis Based on Hilbert-huang Transform and Support Vector Machine," *Applied Acoustics*, Vol. 75, pp. 1-9, 2014.
- [9] P.K. Kankar, Satish C. Sharma, and S.P. Harsha, "Fault Diagnosis of Ball Bearings Using Machine Learning Methods," *Expert Systems with Applications*, Vol. 38, Issue 3, pp. 1876-1886, 2011.
- [10] H. Ocak and K.A. Loparo, "Estimation of the Running Speed and Bearing Defect Frequency of an Induction Motor from Vibration Data," *Mechanical Systems and Signal Processing*, Vol. 18, Issue 3, pp. 515-533, 2004.
- [11] 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.



강 경 원

1996년 부경대학교 전자공학과
학사 졸업(공학사)
1998년 부경대학교 전자공학과
석사 졸업(공학석사)
2002년 부경대학교 전자공학과
박사 졸업(공학박사)

2006년~2014년 ㈜홈케스트 부장
2018년~현재 동명대학교 정보통신공학과 교수
관심분야: 멀티미디어 신호처리, 영상처리, 머신러닝



칼 렵

2015년 영산 대학교 컴퓨터 공학
과 학사 졸업(공학사)
2017년 부경대학교 IT융합응용
공학과 석사 졸업(공학석
사)
2017년~현재 부경대학교 IT융
합응용공학과 박사과정

관심분야: 멀티미디어 신호처리, 영상처리, 머신러닝



이 경 민

2000년 동의대학교 컴퓨터공학과
학사 졸업(공학사)
2002년 동아대학교 전자공학과
석사(공학석사)
2019년 부경대학교 IT융합응용공
학과 박사 졸업(공학박사)

2010년~현재 동명대학교 학부교양대학 교수
관심분야: 멀티미디어 신호처리, 머신러닝



권 기 룡

1986년 경북대학교 전자공학과
학사 졸업(공학사)
1990년 경북대학교 전자공학과
석사 졸업(공학석사)
1994년 경북대학교 전자공학과
박사 졸업(공학박사)

2000년~2001년 Univ. of Minnesota, Post-Doc.
1996년~2006년 부산외국어대학교 디지털정보공학부
부교수
2011년~2012년 Colorado State Univ. Visiting Scholar
2015년~2016년 한국멀티미디어학회 회장
2006년~현재 부경대학교 IT융합응용공학과 교수
2018년~현재 글로벌핀테크산업진흥센터 이사장
관심분야: 멀티미디어정보보호, 영상처리, 멀티미디어
통신 및 신호처리