

인공신경망을 이용한 DWT 전력스펙트럼 밀도 기반 자동화 기계 고장 진단 기법

강경원*

동명대학교 정보통신공학과

Fault Diagnosis Method for Automatic Machine Using Artificial Neural Network Based on DWT Power Spectral Density

Kyung-Won Kang*

Dept. of Information and Communication Engineering, Tongmyong University

요 약 소리 기반 기계 고장 진단은 기계의 음향 방출 신호에서 비정상적인 소리를 자동으로 감지하는 것이다. 수학적 모델을 사용하는 기존의 방법은 기계 시스템의 복잡성과 잡음과 같은 비선형 요인이 존재하기 때문에 기계 고장 진단이 어려웠다. 따라서 기계 고장 진단의 문제를 패턴 인식 문제로 해결하고자 한다. 본 논문에서 DWT와 인공신경망 기반 패턴 인식 기법을 이용한 자동화 기계 고장 진단 기법을 제안한다. 기계의 결함을 효과적으로 탐지하기 위해 DWT를 이용해 대역별 분해 후 최상위 고주파 부대역과 최하위 저주파 부대역을 제외한 나머지 부대역의 PSD를 구하여 인공신경망 기반 분류기의 입력으로 사용한다. 그 결과 본 연구에서 제안한 방법은 효과적으로 결함을 탐지할 뿐만 아니라 소리 기반의 다양한 자동 진단 시스템에도 효과적으로 활용될 수 있음을 보여준다.

• 주제어 : 인공신경망, 이산 웨이브릿 변환, 기계 고장진단, 심층학습, 패턴 인식

Abstract Sounds based machine fault diagnosis recovers all the studies that aim to detect automatically abnormal sound on machines using the acoustic emission by these machines. Conventional methods that use mathematical models have been found inaccurate because of the complexity of the industry machinery systems and the obvious existence of nonlinear factors such as noises. Therefore, any fault diagnosis issue can be treated as a pattern recognition problem. We propose here an automatic fault diagnosis method of hand drills using discrete wavelet transform(DWT) and pattern recognition techniques such as artificial neural networks(ANN). We first conduct a filtering analysis based on DWT. The power spectral density(PSD) is performed on the wavelet subband except for the highest and lowest low frequency subband. The PSD of the wavelet coefficients are extracted as our features for classifier based on ANN the pattern recognition part. The results show that the proposed method can be effectively used not only to detect defects but also to various automatic diagnosis system based on sound.

• Key Words : Artificial Neural Network, Discrete Wavelet Transform, Machine Fault Diagnosis, Machine Learning, Pattern Recognition

Received 02 June 2019, Revised 20 June 2019, Accepted 25 June 2019

* **Corresponding Author** Kyung-Won Kang, Dept. of Information and Communication Engineering, Tongmyong University, 428, Sinseon-ro, Nam-gu, Busan, Korea. E-mail : kangkw@tu.ac.kr

I. 서론

기계 시스템의 정상적인 상태를 유지하기 위해서는 고장 예측 및 진단 시스템이 필요하다. 기계 시스템이 비정상적인 상태에서 지속적으로 동작할 경우 큰 손상과 심지어 인명의 손실을 초래할 수 있기 때문에 적절한 유지 관리 전략이 필요하다. 과거에는 수학적 모델 수립 기반 매개변수 분석을 통해 기계 작동 조건을 판단하는 전통적인 방법의 연구가 많이 진행되었으나, 실제 기계 시스템의 복잡성과 주변 잡음과 같은 비선형 요인에 의해 수학적 모델 기반 접근법에 한계가 존재하기 때문에 정확한 고장 진단이 어려웠다. 따라서 기계 고장 진단을 체계적으로 수행하기 위한 방법론이 요구되었다[1-3].

기계학습 기법에는 장애 유형을 나타내는 레이블된 정보에 의해 결합 진단하는 인공신경망(Artificial Neural Network, ANN), 퍼지 논리 및 지원 벡터 머신 등이 있다. 특히 인공신경망은 임의의 비선형 함수를 재현할 수 있는 능력을 가지며, 복잡한 패턴 인식에 적합하기 때문에 결합 탐지와 여러 패턴 인식에서 널리 사용된다[4].

또한 인공신경망은 다른 기계학습 알고리즘과 통합을 통해 진단 성능 향상을 이룰 수 있다. 대표적인 방법은 퍼지 논리와 신경망을 조합한 것이다[5]. 지원 벡터 머신 또한 데이터를 분리할 수 있는 최상의 도구를 찾기 위해 데이터의 기하학적 표현을 사용하는 기계학습 방법으로, Wang 등은 v-지원 벡터 머신을 사용한 밀링공정의 공구 상태 모니터링 하는 방법이다 [6].

이외에 기존 대부분의 특징 신호는 시계열을 사용하여 원래 데이터의 통계적 특징을 시간 영역 기반 특징 추출에 초점을 맞추고 있다[7]. 주파수 영역 분석에는 푸리에 변환과 힐버트 변환을 대표적으로 사용하며, 이를 기반으로 주파수 평균 기법, 적응잡음 제거, 고진동수 공진기법, 포락선 분석 등이 제안되었다[8]. 또한 이산 웨이블릿 변환(Discrete wavelet transform, DWT) 기반 시간-주파수 영역에서의 특징 추출 방법도 연구되고 있다[9, 10].

따라서 본 논문에서 효과적인 결합 탐지를 위해 인공신경망을 이용한 DWT 데이터의 음향 전력스펙트럼 밀도 분석을 기반으로 한 자동화 기계 고장 진단 기법을 제안한다.

II. 인공신경망(ANN) 모델

인공신경망은 인간의 뉴런(Neuron)의 동작 원리에 기초해 인공적으로 구현한 것으로 신경 세포의 정보 처리 및 전달 과정과 유사하다. 인공신경망에서 가장 많이 사용되는 방식은 다층 퍼셉트론 신경망으로, 그림 1과 같이 입력층, 출력층 및 하나 이상의 은닉층으로 구성된다. 이는 그림 1과 같이 사람의 신경망을 단순화한 형태로서 여러 가지 입력 데이터를 연결된 뉴런의 가중치와 곱한 후 합한 결과를 활성화함수를 거쳐 다음 노드에 전달하는 방식으로 미지의 시스템이 비선형성을 포함하여도 추정이 가능하게 된다. 이러한 과정은 식 (1)과 같이 근사방적으로 표현이 된다.




Fig. 1. Structure of neural networks

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

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

III. 제안한 고장진단 방법

본 논문에서는 밀링머신이 소재를 가공할 때 공구에서 발생하는 소리를 이용하여 공구에 결함이 있는지를 자동으로 탐지하는 방법을 제시한다. 일반적으로 소리 데이터는 주변 잡음에 영향을 많이 받기 때문에 신호의 잡음에 강인한 방법이 필요하다. 실험을 위한

데이터는 AE(Acoustic Emission) 센서를 이용하여 제조 공정에서 핸드 드릴을 이용해 공구의 공회전 상태의 신호와 정상 상태의 공구와 마모된 비정상 상태의 공구를 이용해 강철판을 깎을 때 생성된 신호이다. 신호의 샘플링 주파수는 44.1kHz이며, 한 번의 처리를 위한 신호의 길이는 0.5s이다. 그림 2는 AE 센서로부터 얻은 신호의 기본적인 통계적 특성을 파악하기 위해 각각의 상태별로 1,000개의 샘플 신호들을 평균한 대표 신호의 시간 영역 신호와 전력스펙트럼 밀도(Acoustic power spectral density, PSD) 신호를 나타낸 것이다. 그림 2(a)는 도구가 공회전 상태의 신호들을 평균한 것이며, 그림 2(b)와 그림 2(c)는 정상 상태의 공구와 마모된 비정상 상태의 공구에 의해 야기된 신호들을 평균한 것을 나타낸 것이다.

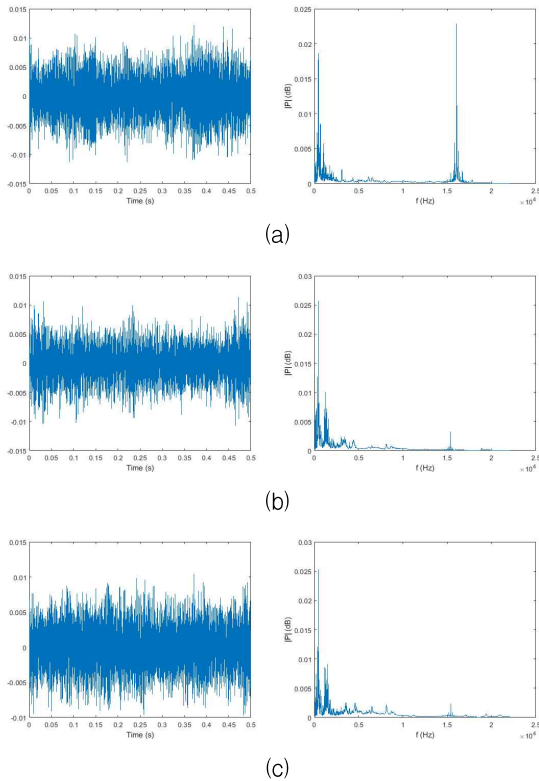


Fig. 2. Sound signals and their corresponding average power spectral density: (a) idle sound data, (b) normal sound data, (c) abnormal sound




Fig. 3. Frequency subband representation of the DWT

대부분의 에너지는 저주파에 집중되어 있으며, 정상 상태의 공구와 마모된 비정상 상태의 공구에 의해 야기된 PSD의 형태는 유사함을 알 수 있다. 유사한 데이터 세트를 사용할 경우 특징 추출에 의한 분류 성능이 저하될 수 있기 때문에, 본 논문에서는 주변 잡음을 제거하고 정상 상태의 공구와 마모된 비정상 상태의 공구의 PSD의 특징을 효과적으로 추출하기 위해 DWT 기반 PSD를 활용한 특징 추출방법을 제안한다.

그림 3은 4레벨 DWT 분해에 따른 주파수 부대역을 나타낸 것이다. 주파수 부대역은 분해 레벨에 따라 1/2씩 감소되며, 최상위의 레벨 1의 고주파 부대역(cD₁)은 22.05kHz~44.1kHz 영역으로 잡음이 포함될 수 있는 부대역이며, 최하위의 레벨 4의 저주파 부대역(cA₄)은 0~2.76kHz 영역으로 상태별 유사성이 강한 부대역이기 때문에 이 두 개의 부대역을 제외한 나머지 부대역에 대해 PSD 기반 특징 추출을 수행한다. 그림 4는 제안한 방법의 흐름도를 나타낸 것이다.

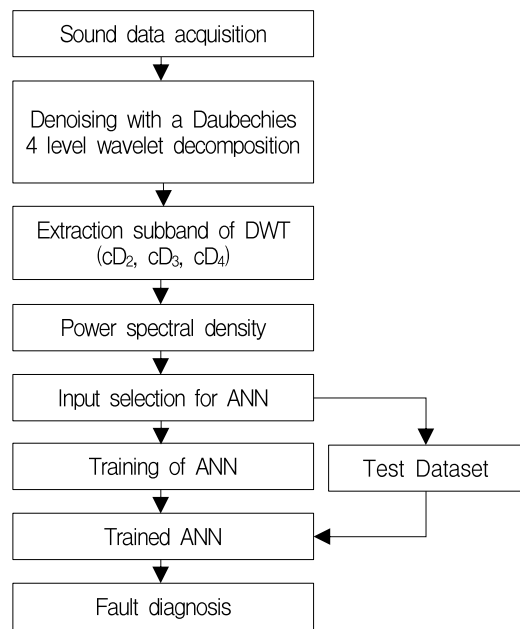


Fig. 4. Flowchart of the proposed method

그림 5는 공회전 상태에서 생성된 PSD의 통계적 특성을 파악하기 위해 각 부대역별 평균한 PSD를 나타낸 것이다. 4레벨 DWT 분해에 의해 최하위의 레벨 4의 저주파 부대역(cA₄)은 0~2.76kHz 대역으로 일반적인 PSD처럼 유사한 형태로 표현되나 각 레벨별 고주파 부대역(cD₂, cD₃, cD₄)은 공구의 상태에 따라 고유의 특징을 나타내고 있다.

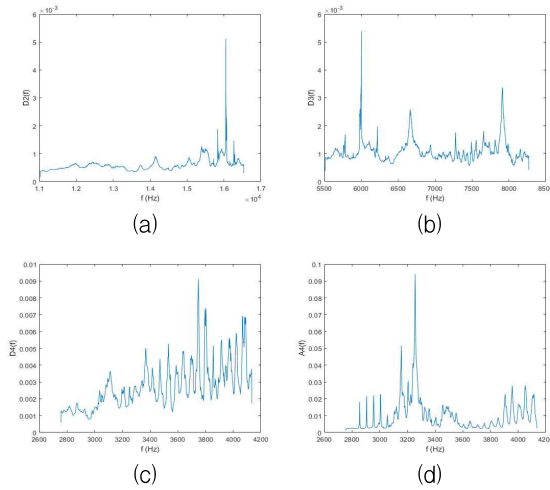


Fig. 5. Average power spectral density of idle sound: (a) cD_2 of DWT, (b) cD_3 of DWT, (c) cD_4 of DWT (d) cA_4 of DWT

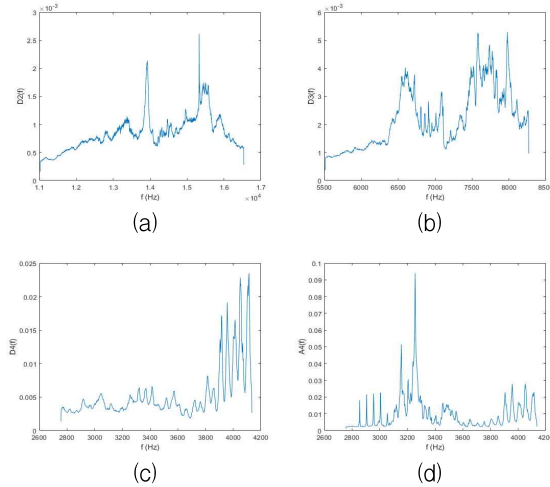


Fig. 6. Average power spectral density of normal sound: (a) cD_2 of DWT, (b) cD_3 of DWT, (c) cD_4 of DWT (d) cA_4 of DWT




Fig. 7. Average power spectral density of abnormal sound: (a) cD_2 of DWT, (b) cD_3 of DWT, (c) cD_4 of DWT (d) cA_4 of DWT

그림 6과 그림 7은 그림 5와 동일하게 정상 상태의 공구와 마모된 비정상 상태의 공구의 평균한 PSD를 나타낸 것이다. 그림 2의 일반적인 PSD의 경우에는 정상 상태의 공구의 PSD와 마모된 비정상 상태의 공구의 PSD가 유사하게 표현되었으나, DWT 분해에 의해 생성된 각 레벨별 고주파 부대역(cD_2 , cD_3 , cD_4)은 공구의 상태에 따라 고유의 특징을 나타내고 있다.

따라서 본 논문에서는 DWT 분해 대역에 대해서 최상위 고주파 부대역(cD_1)을 제외한 각 레벨별 고주파 부대역(cD_2 , cD_3 , cD_4)에 대해 인공신경망을 이용한 자동화 기계 고장 진단 기법을 제안한다.

IV. 실험 결과 및 고찰

본 실험에서는 마이크를 사용하여 밀링머신의 공회전 상태에서 생성된 소리와 정상 상태의 공구와 마모된 비정상 상태의 공구를 사용하여 강철판을 깎을 때 생성된 소리를 각각 500s씩 수집하였다. 수집된 소리 데이터의 샘플링 주파수는 44.1kHz이며, 0.5s 길이로 각각 1,000개의 데이터 세트를 구성하여 인공신경망을 이용한 패턴 인식을 수행하였다.

인공신경망의 입력 데이터는 각각 수집한 데이터를 4레벨 DWT 분해 후 레벨 2에서부터 레벨 4까지의 고주파 대역(cD_2 , cD_3 , cD_4)에 대한 PSD를 사용하였으며, 10개의 은닉 뉴런과 마지막 3개의 뉴런(공회전, 정상, 비정상)으로 구성하였다. 그림 8은 본 논문에서 적용된 인공신경망 네트워크를 나타낸 것으로, 입력 특징 벡터의 수는 2,756개의 cD_2 계수와 1,382개의 cD_3 계수, 693개의 cD_4 계수로 구성하였으며, 입력 데이터의 70%는 훈련 셋(training set)으로 사용되었으며, 15%는 검증 셋(validation set)으로, 나머지 15%는 시험 셋(test set)으로 사용되었다.




Fig. 8. Our network: 4,834 inputs neurons, 10 Hidden neurons and 3 Output neurons




Fig. 9. Performance table

그림 9는 훈련 Epoch에 대한 훈련 기록 오차 값의 나타낸 것이다. 손실함수는 오차 값의 추이를 분석하기 위해 분류를 위한 Cross-Entropy가 아닌 평균 제곱 오차(Mean square error)를 사용하였다. 일반적으로 훈련 Epoch가 더 많아지면 오차가 감소하지만, 네트워크가 훈련 데이터를 과적합(overfitting)하기 시작하면 검증 데이터 셋에 대해 오차가 증가할 수 있다.

은닉 뉴런의 수에 따른 분류 정확도에 미치는 영향을 확인하기 위해 은닉 뉴런의 수를 2~12까지 변경 후 분류 정확도를 확인하였다. 통계적인 특성을 위해 100번 반복한 결과를 그림 10과 같이 나타내었다. 은닉 뉴런의 수가 10 이상인 경우 정확도가 수렴하여, 본 논문에서는 은닉 뉴런의 수를 10으로 고정하여 테스트하였다.

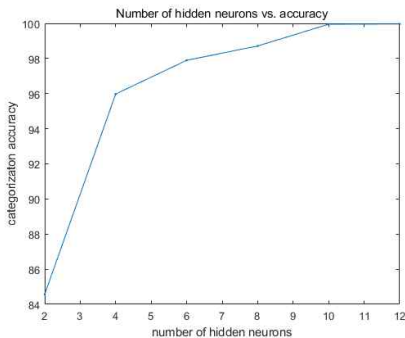


Fig. 10. Relationships between categorization accuracy and number of hidden neurons

제안한 밀링머신의 공회전 상태 및 정상 상태, 비정상 상태의 데이터 1,000개의 대한 결과는 그림 11의 테스트 및 유효성 검사를 위해 혼동 행렬로 표현하였다. 은닉층이 8인 경우 평균적으로 98%의 분류 정확도를 나타냈으며, 은닉층이 10 이상인 경우에는 거의

100% 분류 정확도를 나타내어 우수한 분류 능력을 보이는 것을 확인하였다.

Output Class	1	2	3	
1	1000 33.3%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	1000 33.3%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	1000 33.3%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	1	2	3	

Fig. 11. Confusion matrix of all dataset (class 1: idle class 2: normal, class 3 : abnormal)

V. 결론

본 논문에서 제안한 인공지능망을 이용한 DWT 전력스펙트럼 밀도 기반 자동화 기계 고장 진단 기법은 소리를 이용한 패턴 인식 기반 공구의 결함 진단에서 우수한 성능을 제시하였다. 소리의 특성을 효과적으로 추출하기 위해 DWT를 이용해 대역별 분해 후 특성이 내재된 일부 부대역의 PSD만 활용함으로써 인공지능망을 통한 효과적인 특징 추출을 통한 분류기의 높은 성능을 나타낼 수 있음을 확인하였다. 특히 최상위 고주파 부대역 부분을 제외함으로써 주변 잡음에 강인한 특성을 얻을 수 있었으며, 공동적인 특징을 내포한 최하위 저대역 부분을 제외함으로써 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.

ACKNOWLEDGMENTS

본 논문은 2018학년도 동명대학교 교내학술연구비 지원에 의하여 연구되었음(2018A003).

REFERENCES

- [1] B. Robert and J. Antoni, "Rolling element bearing diagnostics," *Mechanical System and Signal Processing*, vol. 25, no. 2, pp. 485-520, 2011.
- [2] T. H. Ioutas, G. Sotiriades, I. Kalaitzoglou, and V. Kostopoulos, "Condition monitoring of a single stage gearbox with artificially induced gear cracks utilizing on-line vibration and acoustic emission measurements," *Applied Acoustics*, vol. 70, pp.1148-1159, 2009.
- [3] N.R. Sakthivel, B.B. Nair, V. Sugumaran, and R.S. Rai, "Application of Standalone System and Hybrid System for Fault Diagnosis of Centrifugal Pump using Time Domain Signals and Statistical Features," *International Journal of Data Mining Modeling and Management*, vol. 4, no. 1, pp. 74-104, 2012.
- [4] B. Samanta, K.R. Al-Balushi, and S.A. Al-Araimi, "Artificial Neural Networks and Genetic Algorithm for Bearing Fault Detection," *Soft Computing*, vol. 10, issue 3, pp. 264-271, Feb. 2006.
- [5] C. Chen, B. Zhang, G. Vachtsevanos, and M. Orchard, "Machine Condition Prediction Based on Adaptive Neuro-Fuzzy and High-Order Particle Filtering," *IEEE Trans. Industrial Electronics*, vol. 58, issue 9, pp. 4353-4364, Sep. 2011.
- [6] 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, Jan. 2014.
- [7] M. Saimurugan and K.I. Ramachandran, "Comparative Study of Sound and Vibration Signals in Detection of Rotation Machine Faults Using Support Vector Machine and Independent Component Analysis," *International Journal of Data Analysis Techniques and Strategies*, vol. 6, no.1 2, pp. 188-204, 2014.
- [8] H. Ocak and K.A. Loparo, "Estimation of the Running Speed and Bearing Defect Frequencies of an Induction motor from Vibration Data," *Mechanical Systems and Signal Processing*, vol. 18, issue 3, pp. 515-533, 2004.
- [9] P.K. Kankar, S.C. Sharma, and S.P. Harsha, "Fault Diagnosis of Ball Bearings using Continuous Wavelet Transform," *Applied Soft Computing*, vol. 11, issue 2, pp. 2300-2312, 2011.
- [10] Y.S. Wang, C.M. Lee, D.G. Kim, and Y. Xu, "Sound-Quality Prediction for Nonstationary Vehicle interior Noise Based on Wavelet Pre-processing Neural Network Model," *Journal of Sound and Vibration*, vol. 299, Issues 4-5, pp. 933-947, 2007.

저자 소개

강 경 원 (Kyung-Won Kang)



1996년 2월 : 부경대학교

전자공학과(공학사)

1998년 2월 : 부경대학교

전자공학과(공학석사)

2002년 2월 : 부경대학교

전자공학과(공학박사)

2006년 ~ 2014년 : (주)홈케스트

2018년 3월 ~ 현재 : 동명대학교 정보통신공학과 교수

관심분야 : 영상 신호 처리, 머신러닝