Journal of Korea Multimedia Society Vol. 21, No. 8, August 2018(pp. 837-848)
https://doi.org/10.9717/kmms.2018.21.8.837

주파수 영역의 통계적 특징과 인공신경망을 이용한 기계가공의 사운드 모니터링 시스템

이경민[†], 칼렙[††], 이석환[†††], 권기룡[††††]

Sound Monitoring System of Machining using the Statistical Features of Frequency Domain and Artificial Neural Network

Kyeong-Min Lee[†], Caleb Vununu[††], Suk-Hwan Lee[†††], Ki-Ryong Kwon[††††]

ABSTRACT

Monitoring technology of machining has a long history since unmanned machining was introduced. Despite the long history, many researchers have presented new approaches continuously in this area. Sound based machine fault diagnosis is the process consisting of detecting automatically the damages that affect the machines by analyzing the sounds they produce during their operating time. The collected sound is corrupted by the surrounding work environment. Therefore, the most important part of the diagnosis is to find hidden elements inside the data that can represent the error pattern. This paper presents a feature extraction methodology that combines various digital signal processing and pattern recognition methods for the analysis of the sounds produced by tools. The magnitude spectrum of the sound is extracted using the Fourier analysis and the band-pass filter is applied to further characterize the data. Statistical functions are also used as input to the nonlinear classifier for the final response. The results prove that the proposed feature extraction method accurately captures the hidden patterns of the sound generated by the tool, unlike the conventional features. Therefore, it is shown that the proposed method can be applied to a sound based automatic diagnosis system.

Key words: Machining, Band-pass Filter, Magnitude Spectrum, Fourier Analysis, Statistical Functions, Machine Fault Diagnosis,

1. 서 론

기계가공 모니터링 시스템은 공구와 소재가 맞닿는 곳에서 발생하는 물리적인 현상들을 센서를 통해 데이터를 취득하고 적절히 처리하여 필요한 정보를 얻어내는 과정이다. 기계가공 모니터링 분야에 대한

※ Corresponding Author : Ki-Ryong Kwon, Address: Dept. of IT Convergence and Application Eng., Pukyong Nat'l Univ., 45 Yongso-ro, Nam-gu, Busan, Korea, TEL : +82-51-629-6257, FAX : +82-51-629-6230, E-mail : krkwon@pknu.ac.kr
Receipt date : Jul. 15, 2018, Approval date : Jul. 24, 2018
[†] Dept. of IT Convergence and Application Engineering, Pukyong National University
(E-mail : kmlee2k@gmail.com)
[††] Dept. of IT Convergence and Application Engineering, Pukyong National University
(E-mail : exen.xmen@gmail.com)
[†††] Dept. of Information Security, Tongmyong University
(E-mail : skylee@tu.ac.kr)
[††††] Dept. of IT Convergence and Application Engineering, Pukyong National University
※ This work was supported by the Korea Technology and Information Promotion Agency for SMEs(TIPA) grant funded by the Korea government(Ministry of SMEs and Startups) (No. C0407372) and Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Science and ICT (No. 2016R1D1A3B03931003, No. 2017R1A2B2012456) and the MSIT(Ministry of Science and ICT), Korea, under the Grand Information Technology Research Center support program(IITP-2018-2016-0-00318) supervised by the IITP(Institute for Information & communications Technology Promotion)"

많은 연구들이 오래전부터 소개되었으며 일정 기간의 연구들은 리뷰페이퍼 형태로 정리되거나 책으로 출판되어 이 분야의 연구자들에게 많은 도움을 주고 있다[1,2]. 또한 제4차 산업혁명의 중요한 토대 중 하나가 모니터링 기술이라는 점에 있어서 기계가공 모니터링 분야에 대한 현장의 요구는 지속적으로 확대될 것으로 기대된다. 기계가공 모니터링에서 공구는 가공 공정의 효율과 가공된 제품의 품질에 직접적으로 큰 영향을 미치는 요소이다. 절삭공정의 모니터링과 관련된 많은 수의 연구들이 공구의 마모 상태를 실시간으로 감지하거나, 선행 실험을 통해 학습된 데이터를 바탕으로 공구마모 시점을 예측하는 것에 초점을 맞추고 있다. 공구의 마모나 파손을 감지하거나 발생 시점을 예측할 수 있게 되면, 작업자는 단편적인 조치로서는 적절한 시점에 공구를 교체하여 공정의 문제 발생과 제품의 품질 저하를 방지할 수 있다. 한걸음 더 나아가서는 공구의 마모 발생 을 최소화하는 공정 조건을 찾아 보다 효율적인 공정 운영을 할 수 있다.

기계가공 모니터링은 기계에서 생성될 수 있는 진동 또는 음향과 같은 신호의 분석과정을 거치는데, 불행히도 이러한 신호는 실제 작업환경에서 발생할 수 있는 여러 가지 잡음으로 인해 손상 정보를 발견할 수 있는 효과적인 신호처리 기술이 필요하다. 따라서 모니터링 행위는 데이터 흐름의 관점에서 볼 때 패턴 인식 방법으로 볼 수 있다[3].

패턴 인식 방법으로 데이터 수집은 분석에 사용될 신호를 수집하는 단계로 사운드 데이터는 기계의 작동 상태를 잘 전달할 수 있는 능력을 입증했다[4]. 본 논문에서는 밀링머신에서 공구가 알루미늄 대상체를 깎으면서 발생되는 소리를 사용한다. 소리는 정상 공구와 공구 날의 손상 정도가 보통이거나 심한 경우로 3가지로 구성된다. 특징 추출은 수집된 데이터의 최상의 표현을 찾아 공구의 마모 상태를 잘 나타낼 수 있는 특정 구성 요소를 선택하는 단계이다. 실제로 수집된 데이터는 환경적으로 많은 잡음과 중복요인으로 어떠한 변환 없이 그대로 사용하면 평가의 정확성 뿐만 아니라 처리 시간 측면에서도 큰 문제가 될 수 있다. 모든 패턴 인식 방법은 획득된 데이터는 짧고 정확한 형식으로 표현되어야 모니터링의 최종 단계에서 진단의 정확도를 높일 수 있다. 따라서 가장 좋은 특징 선택은 수집된 데이터 사이에 숨겨진 차이점을 분명하게 구분하여 최종 진단의 성능을 높일 수 있는 것이어야 한다. 공구 마모 감지는 패턴 인식 방법의 마지막 단계이다. 공구의 상태를 추론하는 것으로 입력된 신호가 어떤 마모의 상태인지를 분류하는 기준의 정확성을 높여야 한다. 이 분류기의 성능은 입력에 따라 크게 달라지므로 원래의 데이터를 잘못 표현하면 성능이 떨어지며, 즉 좋은 특징 추출은 성공적인 성능을 제공한다.

기존 대부분의 특징 신호는 시계열을 사용하여 원래 데이터의 통계적 특징을 계산함으로써 시간 영역 기반 분석에 초점을 맞추고 있다[5]. 웨이블릿 변환에 의해 제공되는 시간-주파수 영역 또한 특징 추출 방법으로 채택 될 수 있다[6,7].

본 논문에서는 데이터의 스펙트럼 크기를 기반으로 한 특징 추출 방법을 제안하고 최적의 특징을 구성하기 위해 통계적 특징 방법을 사용한다. 데이터는 정상 공구, 마모가 보통인 것과 마모가 많이 되어 사용할 수 없는 상태의 공구인 3가지 형태를 사용한다. 먼저 푸리에 분석을 사용하여 각 데이터의 스펙트럼 크기를 계산한다. 각 데이터가 가지고 있는 차이점을 최대화 하고, 중복 데이터를 제거하기 위해 대역 통과 필터를 적용한 후 통계 기법을 적용한다. 마지막으로, 선택된 특징은 최종 차별을 위한 비선형 분류기의 입력으로 사용되고, 그 출력은 시스템의 최종 진단을 나타낸다. 결과적으로 제안된 특징 추출 방법이 기존의 특징과 달리 도구에서 생성된 소리의 숨겨진 패턴을 정확하게 포착한다는 것을 증명한다. 따라서 제안된 방법은 사운드 기반 자동 진단 시스템에 적용될 수 있음을 보인다.

다음 섹션에서는 본 논문에서 고려해야할 사항과 제안된 방법에 대해서 논의를 할 것이고, 3장에서는 실험을 통해 얻은 결과를 상세히 제시한다. 또한 우리의 방법과 다른 특징 추출 방법들과의 비교 연구를 수행하고, 마지막으로 결론을 맺는다.

2. 관련 연구

모니터링 행위는 데이터를 취득하고 적절히 처리

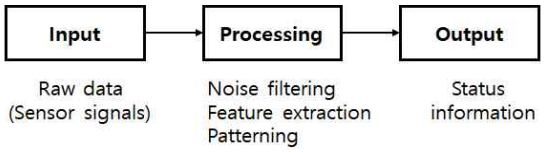

Fig. 1. Data flow of monitoring system.

하여 필요한 정보를 얻어내는 과정이다. Fig. 1은 데이터 흐름의 관점에서 모니터링 시스템을 살펴본 것이다. 데이터를 취득하기 위해서는 목적에 맞는 센서가 선정되어야 하고, 선정된 센서를 통해 취득한 신호는 노이즈를 제거하고 분석하는 과정을 거쳐서 공정의 상태를 정의할 수 있는 정보로 변화하게 된다.

2.1 Sensor signals

공구의 마모 상태를 감지하기 위한 대부분의 모니터링 시스템은 힘 센서 기반으로 가공 부하 변화를 관찰하거나 가속도 센서 기반으로 시스템 진동의 변화를 관찰하는 형태의 간접적인 접근이 주로 이루어진다. 필요에 따라 센서의 종류나 개수의 적용은 달라지지만, 기본적으로 센서를 이용하여 수집된 데이터를 기초로 하여 노이즈 신호를 걸러내고, 다양한 분석 기법을 이용하여 목적에 맞게 신호를 패턴화하고 마모 상태를 분류하는 기준의 정확성을 높여서 활용성을 갖추도록 하는 연구 과정은 유사하다.

진동 신호는 진동의 주파수를 포착하기 위한 압전 트랜스듀서 (piezo-electric transducer) 또는 진동의 가속 데이터를 포착하기 위한 가속도계를 사용하여 수집 할 수 있다. 진동 데이터의 주파수 성분을 사용하여, 진단 모니터링을 할 수 있으며, Wang et al.[8]은 진동 신호를 수집하고 WPD(Wavelet Packet Decomposition)를 기반으로 특성 벡터를 추출하는 공구 상태 모니터링 프레임 워크를 구성하였다. 음향방출(Acoustic Emission, AE) 신호에 대하여 음향방출 센서나 마이크로폰을 이용한 공구마모 모니터링 시스템 구축 사례들도 보고되었다[9,10]. AE는 재료가 약간의 응력이나 하중을 받을 때 발생하는 소리와 초음파의 현상으로 정의되므로, 기계적으로 된 구조물 및 구성 요소에서 결함을 감지하고 위치를 찾는데 일반적으로 사용되는 비파괴 검사 방법이다. 이 기술은 에너지 파동을 포착할 수 있는 초음파 센서를 사용하는 것으로 높은 대역대의 신호처리가 필수적이다. 사운드 신호의 경우 기타 주변 소음으로 인한 잡음이 많아 소리를 사용하는 자동 시스템 평가 체계는 오랫동안 비효율적인 방법으로 간주되었다. 그러나 진동 및 AE와 비교하여 소리를 쉽게 수집할 수 있는 장점은 있다. AE는 물질 내부로 전파되는 형태이고, 진동은 검사 중인 재료의 동적 응답이다. 두 경우 모두 센서는 검사 중인 기계와 접촉해야 한다. 이 경우 소리는 비접촉식의 이점이 있을 수 있고, 사운드 획득 중에 사용되는 마이크는 검사 중인 기계와 접촉하지 않기 때문에 마찰과 관련된 노이즈로 인한 신호의 붕괴를 피할 수 있다. 이러한 요인들이 결합되면 사운드 기반 진단 시스템이 다른 방법과 비교하여 저렴하고 간단하게 설정할 수 있다.

2.2 Processing

기계 고장 진단 및 예측 시스템에서 특징을 추출하기 위해서는 취득 신호를 분석하는 신호 처리 기술이 선행되어야 한다. 신호 처리 기술은 크게 시간 영역 분석, 주파수 영역 분석, 시간-주파수 분석으로 분류 되고 각 영역별로 고장 진단 시스템에 적용되었다. 시간 영역 분석에는 신호로부터 평균, 실효치(RMS, root mean square), 표준편차, 분산, 왜도(skewness), 첨도(kurtosis)와 같은 통계치를 분석하는 방법과 시계열(time-series) 분석이 제안되었고[5], 주파수 영역 분석에는 푸리에 변환과 힐버트 변환을 대표적으로 사용하며, 이를 기반으로 주파수 평균 기법(frequency averaging technique), 적응 잡음 제거(adaptive noise cancellation), 고 진동수 공진기법(high frequency resonance technique), 포락선(envelope) 분석 등이 제안되었다[11]. 시간-주파수 분석에는 비선형적이고 비정상상태의 신호를 분석하는데 용이한 STFT(short-time Fourier transform), Wigner-Ville distribution, Choi-Williams distribution, 웨이블릿 변환 등이 제안되었다[12]. 신호처리 기법을 이용하여 고장 진단 시스템에 적절한 특징벡터를 추출하는 방법들이 연구되었는데, 그 중 대표적인 것이 AR(auto-regressive) 모델의 잔여신호(residual signal)를 이용하는 방법[13] 과 FFT의 N-point를 조절하는 방법[14], 웨이블릿의 대역별 통계치를 이용하는 방법이다[6,7]. 본 논문에서는 주파수 영역의 스펙트럼 크기를 이용해 데이터의 특징을 더 잘 표현하고 잡음을 동시에 제거하는 필터링을 거쳐 통계치를 분석하는 방법을 적용한다.

2.3 Status information

일반으로 패턴 인식 기법은 입력되는 데이터와 기존의 데이터가 특정 유사도나 일정한 형태의 규칙을 가지고 있는지를 비교하는 기법이다. 보통 기계 고장

진단의 경우 신경망을 이용한 패턴 인식 기법을 주로 사용한다. SVM(Support Vector Machine)은 데이터를 분리 할 수 있는 최상의 도구를 찾기 위해 데이터의 기하학적 표현을 사용하는 기계 학습 방법이다. SVM은 레이블이 지정된 데이터 집합을 사용하는 감독 학습 방법으로, Wang et al.[8]은 v-SVM (Support Vector Machine)을 사용하여 밀링공정의 공구 상태 모니터링을 구현하였다. 엔드밀 공정에서 공구 마모를 모니터링하는 한 연구에서는 공구 결함을 실시간으로 감지하는 새로운 방법을 소개하였는데, 이 방법은 절삭 조건과 독립적이며 공구마모와 상관관계가 있는 힘 모델 계수의 실시간 추적을 기반으로 하였다[15]. 또 다른 연구에서는 절삭력을 기초로 BPNs (Back-Propagation Neural Networks)와 ANFIS (Adaptive Neuro-Fuzzy Inference System)을 사용하였다[16]. 이외에 ANN(Artificial Neural Network)은 인상적인 학습 및 기억 능력을 보여준다. 또한 여러 가지 방법으로 결함을 자동으로 탐지하고 여러 패턴 인식에서 널리 사용된다[3]. ANN은 임의의 비선형 함수를 나타낼 수 있고, 복잡한 패턴 인식에 적합하다. 즉, ANN은 매우 복잡한 데이터를 구분할 수 있어 본 논문에서 공구 감지 모니터링 시스템의 분류기로 사용한 것이다.

3. 제안한 방법

본 논문에서는 밀링머신이 소재를 가공할 때 마모된 공구에서 발생하는 소리를 이용하여 공구가 결함이 있는지를 자동으로 인지할 수 있어야 한다. 이 작업의 모든 목적은 정상 공구의 소리와 마모된 공구의 소리를 자동으로 비교할 수 있는 방법을 제시하는 것이다. 여기서 제시된 특징 추출 방법은 주로 소리의 스펙트럼 크기를 추출하여 데이터가 가지는 숨은 차이를 잘 표현할 수 있고, 중복데이터를 제거할 수 있는 대역통과필터를 적용한 후 통계 기법을 사용하는 것이다. 그런 다음 분류기의 입력으로 사용되어 공구 마모를 자동으로 감지한다. Fig. 2는 제안된 시스템의 흐름도를 보인 것이다. 최종 결과는 본 논문에서 제시된 방법이 기존의 방법과 차이점을 발견함으로써 공구가 가지는 특징을 잘 나타낼 수 있음을 보여준다. [5]에 제시된 시간영역의 통계적 특징이 데이터의 특성을 잘 나타낼 수 있으나 본 논문에서 제안한 방법이 더 나은 결과를 증명한다. 또한 [7]에 제시된 시간-주파수 기반의 결과도 우리가 제시한 방법이 더 나음을 증명한다.

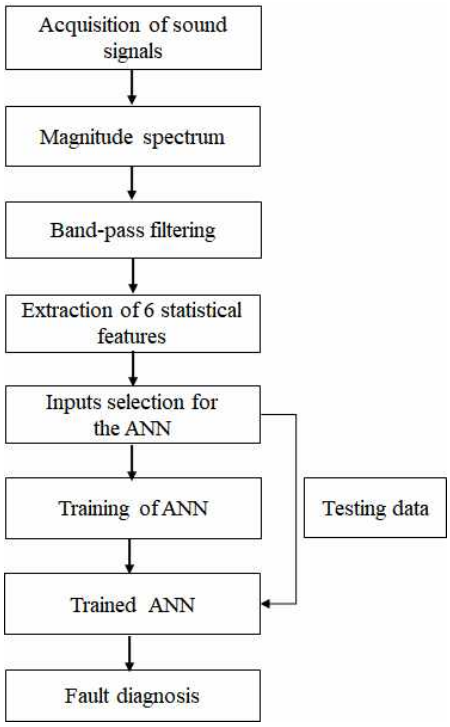

Fig. 2. Flowchart of machining monitoring system.

3.1 Pre-processing

푸리에 분석은 주파수 영역의 데이터를 분석하는데 유용하다. 따라서 푸리에 분석을 사용하여 각 데이터의 스펙트럼 크기를 계산한다. 수집된 데이터 사운드는 N개의 샘플링 포인트를 포함하는 $x(n)$으로 표시되는 1차원 이산 벡터이다. 이산 신호 $x(n)$의 이산푸리에 변환 $X(k)$는 식 (1)을 사용하여 계산할 수 있다.

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-i2\pi kn/N} \tag{1}$$

k의 값은 원 신호 $x(n)$의 주파수 성분을 나타낸다. 따라서 $X(k)$는 주파수 영역에서의 시계열 $x(n)$이고, $X(k)$는 식 (2)와 같이 사인과 코사인의 합으로 분해될 수 있는 복소수를 포함한다.

$$X(k) = \sum_{n=0}^{N-1} x(n) \left[\cos\left(\frac{2\pi kn}{N}\right) - i \cdot \sin\left(\frac{2\pi kn}{N}\right) \right] \tag{2}$$

$X(k)$는 복소수이며, $Re(X_k)$ 및 $Im(X_k)$가 각각

$X(k)$의 실수부 및 허수부를 표현한다면 모든 단일 주파수 값 k의 크기 $|X(k)|$는 식 (3)을 사용하여 계산할 수 있다.

$$|X(k)| = \sqrt{Re(X_k)^2 + Im(X_k)^2} \tag{3}$$

Fig. 3에서는 샘플 사운드 데이터와 해당 데이터의 스펙트럼 크기를 보여준다. Fig. 3(a)는 정상 공구에서 수집된 데이터 중 하나로 왼쪽은 사운드 데이터이고, 오른쪽은 스펙트럼 크기를 나타낸 것이다. Fig. 3(b)는 마모가 보통인 공구에서 수집된 데이터 중 하

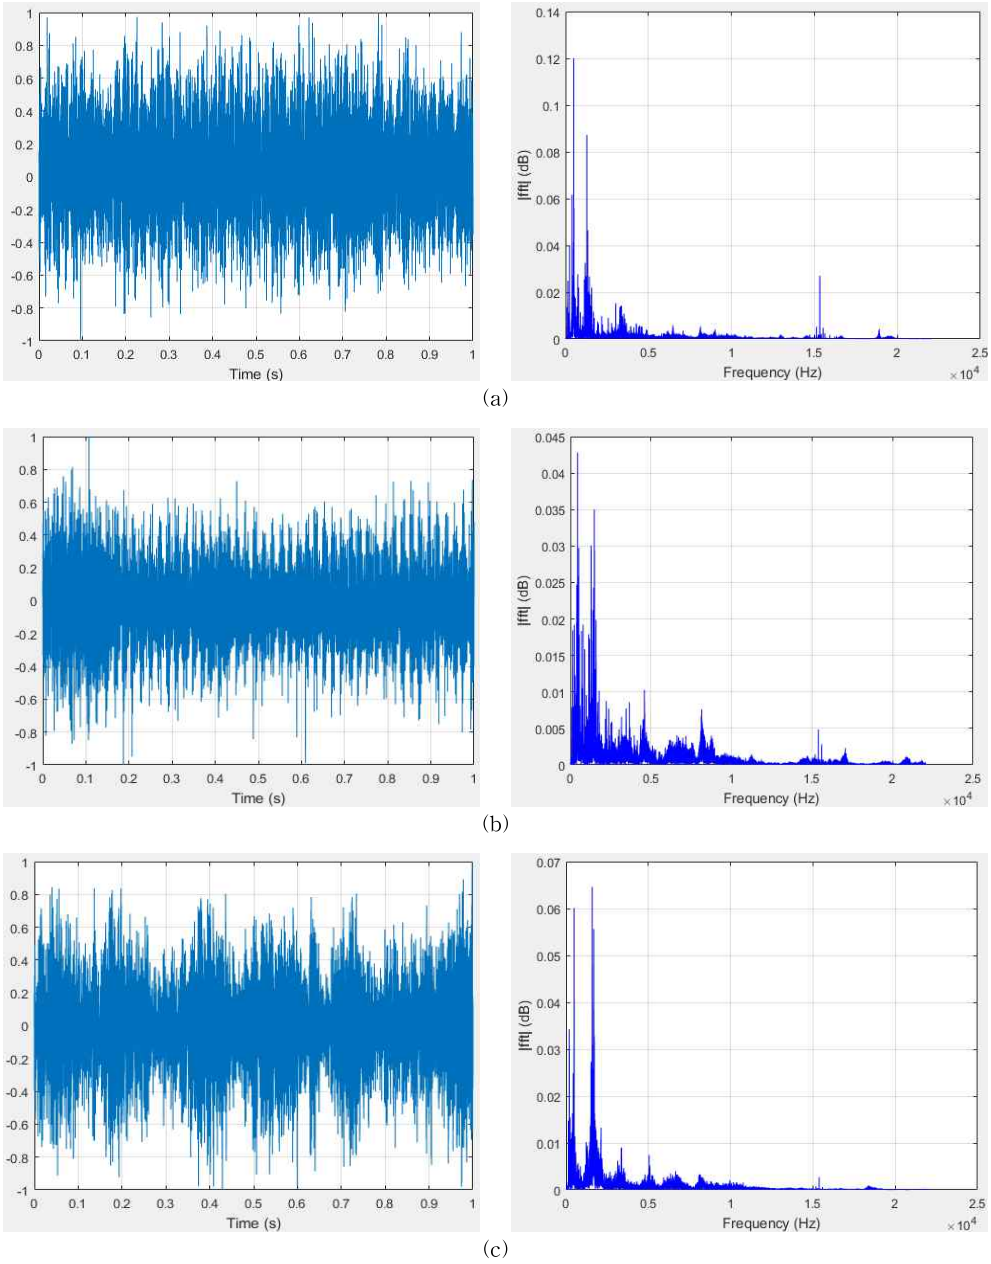

Fig. 3. Sound data and magnitude spectrum: (a) normal tool sound data and its corresponding magnitude spectrum, (b) mild wear tool sound data and its corresponding magnitude spectrum, (c) severe wear tool sound data and its corresponding magnitude spectrum.

나로 왼쪽은 사운드 데이터이고, 오른쪽은 해당 데이터의 스펙트럼 크기이다. Fig. 3(c)는 마모가 심해 사용할 수 없는 공구에서 수집된 데이터 중 하나로 왼쪽은 사운드 데이터이고, 오른쪽은 해당 데이터의 스펙트럼 크기이다. 각 데이터의 스펙트럼의 크기를 비교하면서 유용한 정보가 주로 고주파수 대역에 어떻게 위치해 있는지 알 수 있다.

보통 대부분의 에너지가 집중되는 곳에 신호의 중요한 정보들이 포함되어 있어 대역통과필터를 사용한다. Fig. 3은 데이터 세트로부터 선택된 샘플의 푸리에 변환을 보여준다. 대부분의 에너지는 0Hz 와 2,500Hz 사이의 저주파 영역에 집중되어 있음을 알 수 있다. 하지만 에너지가 최대인 영역을 사용한다고 해서 데이터가 뚜렷이 구별되지는 않는다. 따라서 Fig. 4에서처럼 데이터들이 구별될 수 있는 15,000Hz 와 16,000Hz 대역에서 유용한 정보를 추출하려한다. 실제로 매우 유사한 데이터 세트를 사용하면 특징 추출 방법이 효과적이지 않으며 분류의 성능도 떨어져 진단 분석이 용이하지 못 하다.

Fig. 5는 대역통과필터를 적용한 스펙트럼 크기와 그에 대한 사운드 데이터이다. Fig. 5(a)는 정상 공구에서 수집된 데이터 중 하나로 왼쪽은 필터링된 스펙트럼 크기이고, 오른쪽은 그에 대한 사운드 데이터이다. Fig. 5(b)는 마모가 보통인 공구에서 수집된 데이터이고, Fig. 5(c)는 마모가 심해 사용할 수 없는 공구에서 수집된 데이터 중 하나로 각각 왼쪽은 필터링된 스펙트럼 크기이고, 오른쪽은 해당 사운드 데이터이다. 해당 사운드 데이터는 필터링이 적용되어도 샘플

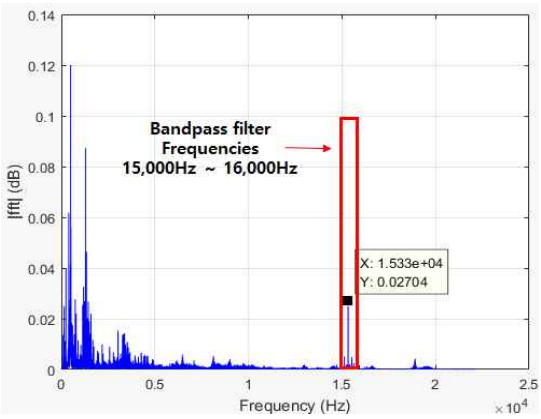

Fig. 4. The chosen filtering process: a band-pass filter from 15,000Hz to 16,000 Hz.

포인트 수가 44,100개여서 시각적으로 많이 줄어든 것 같아 보이지 않을 수 있다.

3.2 Feature Extraction

필터링된 주파수 영역에서 주로 사용되는 대표적인 통계적 특징 6가지를 사용하였다. 뉴럴 네트워크의 입력으로 사용된 각 신호에 대한 6가지 통계치는 다음과 같다.

a) Range: 신호의 최대값과 최소값의 차이를 나타낸다.

$$range = \max(x_i) - \min(x_i) \tag{4}$$

b) Mean value: 신호의 평균값이다.

$$mean\ value = \frac{1}{N}\sum_{i=1}^{N} x_i \tag{5}$$

c) Standard deviation: 신호의 에너지 함량을 측정한다. x는 신호이고, N은 x의 총 수이며, $\bar{x}$ 는 x의 평균이다.

$$standard\ deviation = \frac{1}{N-1}\sum_{i=1}^{N}(x_i - \bar{x})^2 \tag{6}$$

d) Skewness: 신호 대칭을 측정한다. 여기서 $\bar{x}$는 x의 평균, σ는 x의 표준 편차이다.

$$Skewness = \frac{1}{N}\sum_{i=1}^{N}\left(\frac{x_i - \bar{x}}{\sigma}\right)^3 \tag{7}$$

e) Kurtosis: 데이터가 정규 분포에 비례하여 정점에 있거나 평평한지 여부를 측정한다. Skewness와 같은 평균 및 표준 편차를 사용한다.

$$kurtosis = \frac{1}{N}\sum_{i=1}^{N}\left(\frac{x_i - \bar{x}}{\sigma}\right)^4 \tag{8}$$

f) Crest factor: 파형의 피크 진폭을 제곱 평균 제곱근으로 나눈 값이다. 여기서 $\max(x)$는 x의 최대값을 나타낸다.

$$crest\ factor = \frac{\max(|x_i|)}{\sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2}} \tag{9}$$

3.3 Artificial Neural Network

인공지능의 한 분야인 인공신경망(Artificial Neural Network : ANN)은 생물학(통상 인간)의 뇌 구조(신경망)를 모방하여 모델링한 수학적 모델이다. 생물학적 신경망을 모방하여 인공신경망을 모델링

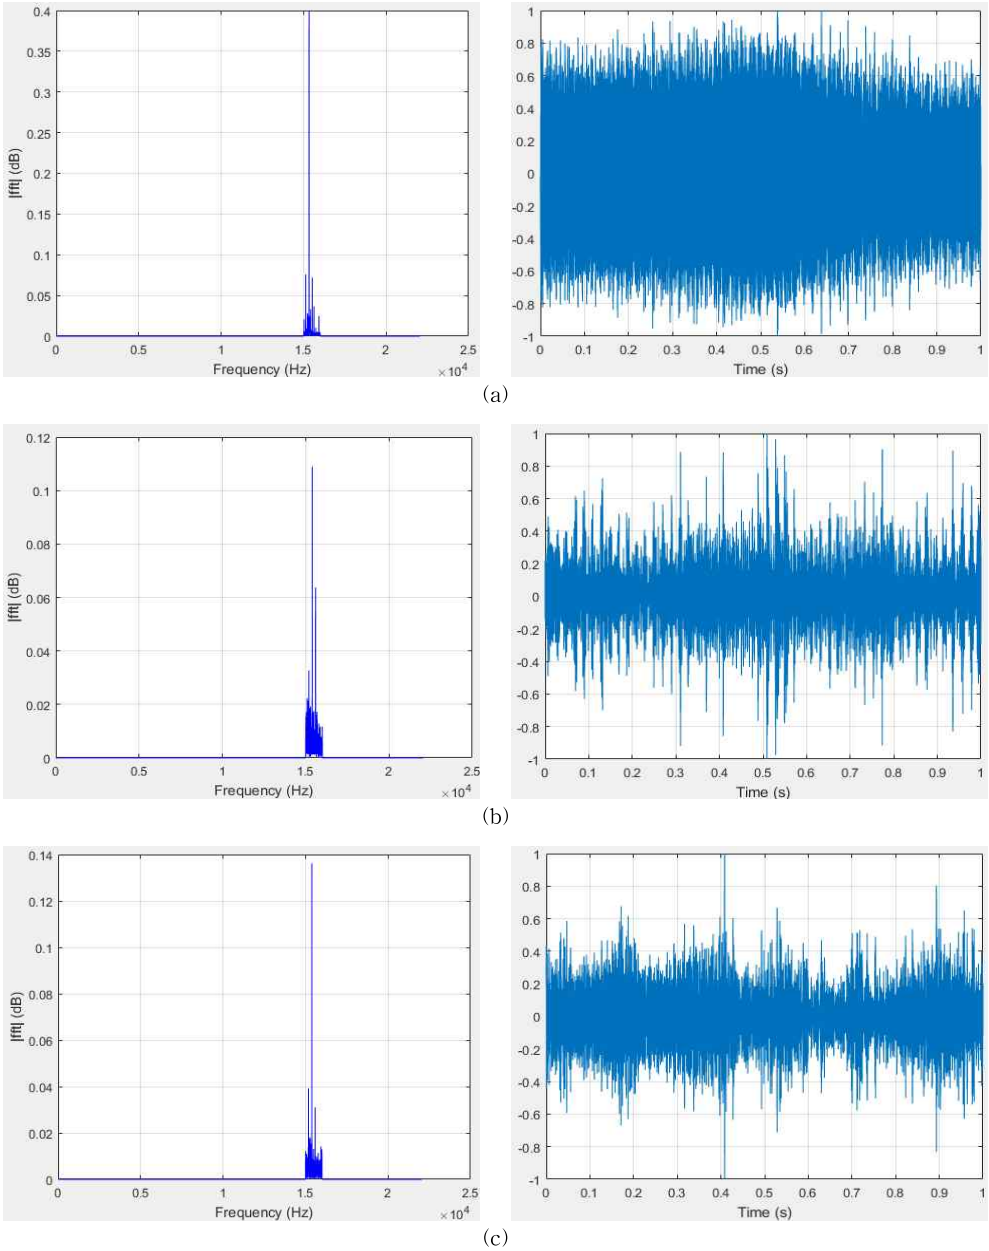

Fig. 5. Magnitude spectrum and sound data of filtered versions: (a) normal tool (b) mild wear tool (c) severe wear tool.

한 내용을 살펴보면 처리 단위(processing unit) 측면에서는 생물적인 뉴런(neurons)이 노드(nodes)로, 연결성(connections)은 시냅스(synapse)가 가중치(weights)로 모델링 되었다. ANN은 비선형 모델로 패턴 인식과 함께 다양한 방법으로 결함을 자동 탐지하는 데 널리 사용되고 있다[3]. 즉, 많은 입력들에 의존하면서 일반적으로 베일에 싸인 함수를 추측하고 근사치를 낼 경우 사용한다. 입력으로부터 값을 계산하는 뉴런 시스템의 상호연결로 표현되고 적응성이 있어 패턴인식과 같은 기계학습을 수행할 수 있다. 네트워크는 실제 출력과 원하는 출력사이에서 오류를 역 전파시킴으로써 학습한다. 본 논문에서 선

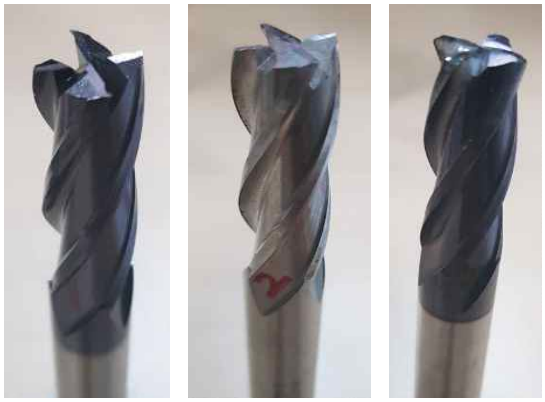

Fig. 6. Tool status used for recording: (a) normal tool, (b) mild wear tool, (c) severe wear tool.

별된 통계적 특징이 신경 네트워크 기반 분류기에 입력으로 주어지며, 그 출력은 모니터링 시스템의 최종 진단을 나타낼 것이다.

4. 실험 결과 및 고찰

본 실험에서는 마이크를 사용하여 밀링머신에서 대상체를 깎을 때 사용된 정상 공구와 마모가 된 공구의 자료를 수집했다. 사운드는 비정적 신호이므로 패턴 인식 단계를 위한 데이터 세트를 구성하기 위해 녹음된 데이터를 많은 부분으로 분할하였다. 사용된 샘플링 주파수와 신호 길이는 각각 44,100Hz와 1sec이고, 정상 공구에서 683개, 마모가 보통인 공구에서 얻은 614개, 마모가 심한 공구에서 475개로 총 1,772개의 데이터 세트를 만들었다. 앞서 언급한 샘플링 주파수와 신호 길이를 사용하여 각 사운드는 44,100개의 포인트를 포함하는 벡터이다. Fig. 6은 실제 녹음에 사용된 공구로 정상 공구와 마모가 보통인 것과 마모가 심한 상태의 공구를 보인 것이다. Fig. 6(c)는 공구의 날 손상이 심하여 4개의 날 부분이 많이 무뎌져 있는 걸 볼 수 있다.

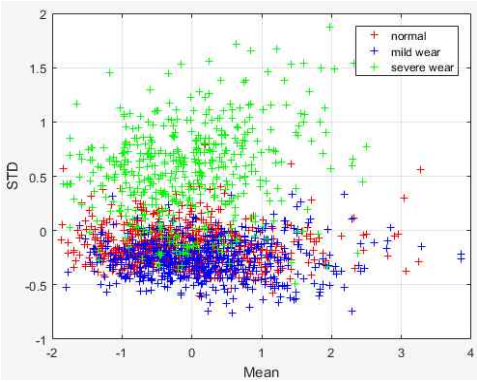

(a)

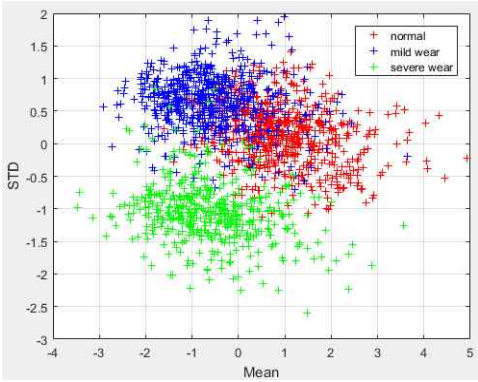

(b)

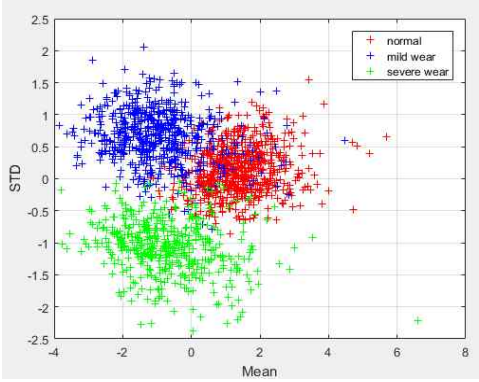

(c)

Fig. 7. Comparison of two statistical projection results by frequency band: (a) 0Hz~2,500Hz (b) 14,000Hz~17,000Hz, (c) proposed frequency band 15,000Hz~16,000Hz.

실험에서 공구별 데이터는 주파수 영역의 스펙트럼의 크기를 이용하였다. 각 데이터가 가지는 특징을 차별화하기 위해 고주파 영역의 대역통과필터를 사용하여 주변의 노이즈도 함께 제거하였다. 필터를 적용한 주파수 영역에서 대표적인 통계치 6가지를 계산하여 특징으로 사용하였다. Fig. 7은 주파수 대역을 각각 달리하여 mean, standard deviation 2개의 통계치를 프로젝션하여 얻은 결과이다. Fig. 7(a)는 0Hz~2,500Hz 저주파 대역의 결과이고, (b)는 14,000 Hz~17,000Hz 대역으로 제안한 대역대보다 범위를 넓혀 얻은 결과이다. (c)는 제안한 15,000Hz~16,000 Hz 대역의 결과로 그림에서 알 수 있듯이 제안한 대역대의 범위가 데이터의 특징을 가장 잘 나타내고 있음을 알 수 있다.

Fig. 8은 mean, standard deviation 2개의 통계치를 프로젝션하여 보인 것으로 Fig. 8(a)는 시계열을 이용한 통계치의 결과이고, (b)는 제안한 방법의 결과이다. 실험 결과에서 알 수 있듯이 시계열에는 진단 목적으로 사용할 수 있는 유용한 정보가 포함되어 있지 않음을 알 수 있다. 시계열의 경우 데이터의 중복성으로 인한 3개의 데이터 세트 모두 상호 연관성이 높아 분리가 잘 되지 않음을 확인할 수 있다. 반면에 제안한 방법의 경우 데이터간의 특징을 잘 표현하여 정상 공구와 마모된 공구간의 데이터 분리가 잘 되고 있음을 알 수 있다.

Fig. 9는 standard deviation과 kurtosis 2개의 통계치를 프로젝션하여 보인 것으로 Fig. 9(a)는 시계열을 이용한 통계치의 결과이고, (b)는 제안한 방법의 결과이다. 앞서 확인한 Fig. 8에서 보여준 것과 유사한 결과를 보인다.

Fig. 8과 Fig. 9는 2개의 통계적 특징을 프로젝션하여 나타내었지만, 신경망 기반 분류기의 입력으로

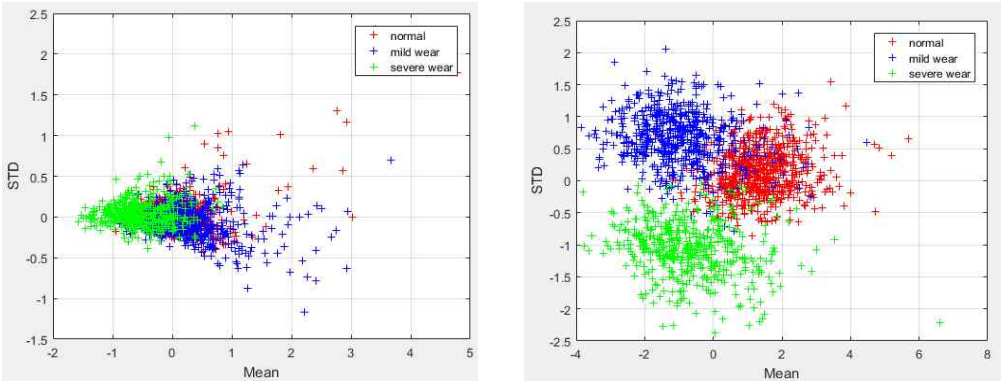

(a) (b)

Fig. 8. Comparison between the statistical features results of: (a) time series, (b) proposed method.

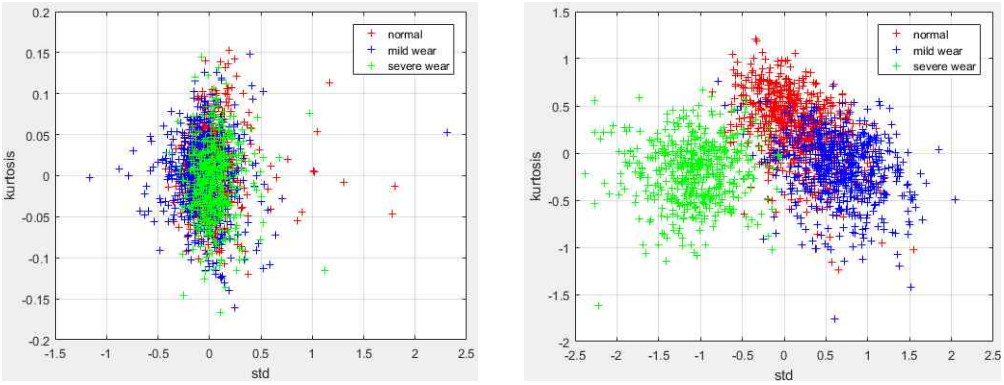

(a) (b)

Fig. 9. Comparison between the two statistical features results of: (a) time series, (b) proposed method.

총 6개의 통계적 특징이 사용되었다. 네트워크에는 3개의 레이어가 있다. 입력 레이어는 통계적 특징에 따라 6개의 뉴런으로 이루어져 있고, 숨겨진 레이어에는 10개의 뉴런이 있으며, 정상 및 보통 마모, 심한 마모에 따라 최종 레이어에 3개의 뉴런이 있다. 각 뉴런은 학습 함수로서 $f(x) = \tanh(x)$ 정의된 시그모이드 함수를 사용한다. 실험에서 1,772개의 데이터를 사용했으며 그 중 70%는 훈련에 사용되었고 나머지 30%는 훈련된 네트워크를 테스트하는 데 사용되었다. 정상 공구의 경우 데이터 세트는 683개로 478개는 훈련용으로 205개는 테스트용으로 사용되어, 199개가 정상 분류되어 97.5%의 정확도를 보였다. 마모가 보통인 공구의 데이터 세트는 614개로 430개는 훈련용으로 184개는 테스트용으로 사용되었고, 그 중 179개가 정상 분류되어 97.2%의 정확도를 보였다. 마모가 심한 공구의 데이터 세트는 475개로 332개는 훈련용으로 143개는 테스트용으로 사용되었고, 그 중 140개가 정상 분류되어 98.6%의 정확도를 보였다. 제안한 분류기의 전체 정확도는 97.8%로 Fig. 10(a)에서 그 결과를 확인할 수 있다. Fig. 10(b)는 [5]에서 제안한 시계열 데이터를 이용한 통계적 특징 추출방법으로 11개의 통계적 특징 중 ICA를 이용해 7개의 특징을 다시 추출하여 SVM의 입력으로 사용하였다. 시계열 데이터의 비효율성으로 전체적으로 낮은 정확도를 보이고, 특히 마모가 보통인 경우는 정상 공구와 분류가 잘 이루어지지 않아 31.5%의 정확도를 보였다.

시계열 데이터를 이용한 결과 외에 시간-주파수 분석을 이용한 비교 연구의 결과는 Table 1에 있다. Table 1에서 제안한 방법의 전체 정확도가 97.8%에 도달한다는 것을 알 수 있다. 분류기에 주어진 데이터는 Fig. 8에서 이미 확인했듯이 서로 다른 3개의 클러스터를 형성하고 있다. 또한 분류기의 입력으로 SVM과 ANN을 비교하여 실험하였고, 비선형 분류기에 강한 ANN이 조금 더 높은 진단 결과를 보였다. 비교 연구는 시계열 데이터의 통계적 특징을 사용한 [5]에서 마모된 공구를 인식하는데 어려움으로 그 중 많은 수가 잘 못 분류되었다. [6]에서 제안된 이산 웨이브렛 변환(DWT) 계수와 [7]에서 제안된 연속 웨이블릿 변환(CWT) 계수는 시간-주파수를 표현한

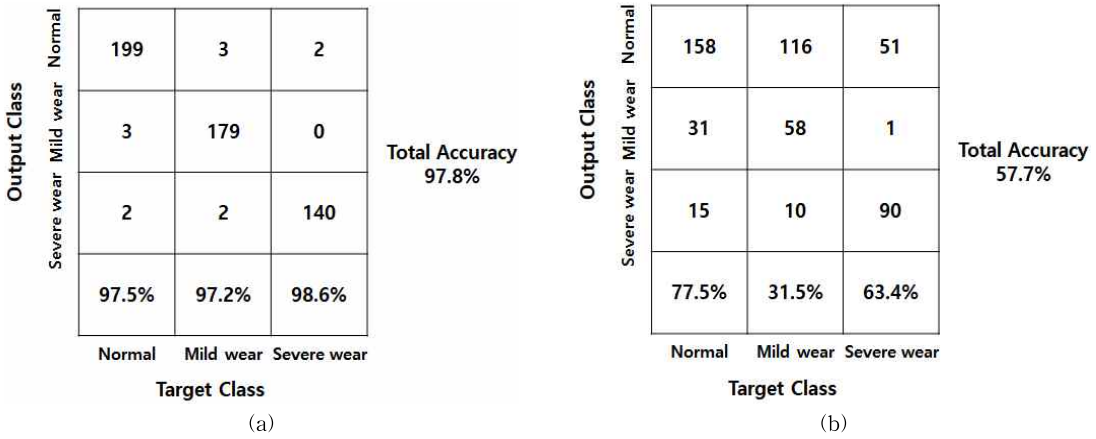

Fig. 10. Confusion matrix of the testing data: (a) proposed method, (b) Using statistical features and ICA over the time series data.

Table 1. Results summary

References	[5]	[6]	[7]	Present work	
Feature Extraction Method	Time series + statistical features + ICA	DWT coefficients + PCA	CWT components + statistical features	FFT + statistical features	
Classifier	SVM	ANN	ANN	SVM	ANN
Classification Accuracy	57.7%	95.7%	75.8%	95.1%	97.8%

다. DWT 계수가 총 95.7%의 결과로 DWT 계수는 여전히 우수하다. 반면 CWT 계수는 Table 1에서 볼 수 있듯이 비정상적인 마모 데이터를 잘 인식하지 못했다.

5. 결 론

본 연구에서 제안된 FFT-Statistical-ANN 방법은 소리를 이용한 공구의 결함 진단에 기반한 패턴 인식에서 탁월한 성능을 발휘할 수 있음을 증명한다. 사운드의 스펙트럼 크기를 추출하여 각 데이터의 특징을 잘 나타낼 수 있는 대역통과필터를 통해 잡음을 함께 제거함으로써 제안한 특징 추출이 분류기의 높은 성능을 나타낼 수 있음을 보여주었다. DWT 및 CWT 계수에 의해 제공되는 시간 영역 및 시간-주파수 영역과 비교할 때, 제안한 특징이 데이터의 주요 특성을 잘 포착함으로써 탁월한 성능을 달성하였다. 여기에 제시된 방법은 다른 고장 진단 시스템에서 사용될 수 있고, 공구의 정상 및 비정상적인 마모된 소리를 분리 할 수 있으면 진동 및 기타 음향 방출 데이터에도 사용할 수 있을 것이다.

REFERENCE

[1] G. Byrne, D. Dornfeld, I. Inasaki, G. Ketteler, W. König, and R. Teti, "Tool Condition Monitoring(TCM)-The Status of Research and Industrial Application," *CIRP Annals*, Vol. 44, No. 2, pp. 541-567, 1995.

[2] R. Teti, K. Jemielniak, G. O'Donnell, and D. Dornfeld, "Advanced Monitoring of Machining Operations," *CIRP Annals*, Vol. 59, No. 2, pp. 717-739, 2010.

[3] 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, 2006.

[4] C. Vununu, J.H. Park, S.H. Lee, and K.R. Kwon, "Sound Based Machine Fault Diagnosis System Using Pattern Recognition Techniques," *Journal of Korea Multimedia Society*, Vol. 20, No. 2, pp. 134-143, 2017.

[5] M. Saimurugan and K.I. Ramachandran, "Comparative Study of Sound 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, 2014.

[6] 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.

[7] 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.

[8] G.F. Wang, Y.W. Yang, Y.C. Zhang, and Q.L. Xie, "Vibration Sensor Based Tool Condition Monitoring Using Support Vector Machine and Locality Preserving Projection," *Sensors and Actuators A: Physical*, Vol. 209, pp. 24-32, 2014.

[9] Y.S. Wang, C.M. Lee, D.G. Kim, and Y. Xu, "Sound-Quality Prediction for Nonstationary Vehicle Interior Noise Based on Wavelet Preprocessing Neural Network Model," *Journal of Sound and Vibration*, Vol. 299, Issues 4-5, pp. 933-947, 2007.

[10] L.H.A. Maia, A.M. Abrao, W.L. Vasconcelos, W.F. Sales, and A.R. Machado, "A New Approach for Detection of Wear Mechanisms and Determination of Tool Life in Turning Using Acoustic Emission," *Tribology International*, Vol. 92, pp. 519-532, 2015.

[11] 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.

[12] L. Dung and M. Mizukawa, "A Pattern Recognition Neural Network Using Many Sets

of Weights and Biases," *Proceeding of the 2007 IEEE International Symposium on Computational Intelligence in Robotics and Automation*, pp. 285-290, 2007.

[13] D.C. Baillie and J. Mathew, "A Comparison of Autoregressive Modeling Techniques for Fault Diagnosis of Rolling Element Bearings," *Mechanical Systems and Signal Processing*, Vol. 10, No. 1, pp. 1-17, 1996.

[14] P.D. McFadden and J.D. Smith, "Monitoring and Diagnosis of Rolling Element Bearing Using Artificial Neural Networks," *IEEE Transactions on Industrial Electronics*, Vol. 40, No. 2, pp. 209-217, 1993.

[15] M. Nouri, B.K. Fussell, B.L. Ziniti, and E. Linder, "RealTime Tool Wear Monitoring in Milling Using a Cutting Condition Independent Method," *International Journal of Machine Tools and Manufacture*, Vol. 89, pp. 1-13, 2015.

[16] T.I. Liu, S.D. Song, G. Liu, and Z. Wu, "Online Monitoring and Measurements of Tool Wear for Precision Turning of Stainless Steel Parts," *International Journal of Advanced Manufacturing Technology*, Vol. 65, No. 9-12, pp. 1397-1407, 2013.

이 경 민

2000년 동의대학교 컴퓨터공학과 학사 졸업(공학사)
2002년 동아대학교 전자공학과 석사 졸업(공학석사)
2014년~현재 부경대학교 IT융합응용공학과 박사과정 수료
관심분야: 멀티미디어 신호처리, 머신러닝

칼 렙

2015년 영산대학교 컴퓨터공학과 학사 졸업(공학사)
2017년 부경대학교 IT융합응용공학과 석사 졸업(공학석사)
2017년~현재 부경대학교 IT융합응용공학과 박사과정
관심분야: 멀티미디어 신호처리, 영상처리, 머신러닝,

이 석 환

1999년 경북대학교 전자공학과 학사 졸업(공학사)
2001년 경북대학교 전자공학과 석사 졸업(공학석사)
2004년 경북대학교 전자공학과 박사 졸업(공학박사)
2005년~현재 동명대학교 정보보호학과 교수
관심분야: 워터마킹, DRM, 영상신호처리

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