

신경회로망 기반 고장 진단 시스템을 위한 고장 신호별 특징 벡터 결정 방법

Feature Vector Decision Method of Various Fault Signals for Neural-network-based Fault Diagnosis System

한형섭*·조상진**·정의필†

Hyungseob Han, Sangjin Cho and Uipil Chong

(2010년 6월 10일 접수 ; 2010년 10월 19일 심사완료)

Key Words : Fault Diagnosis(고장 진단), Feature Extraction(특징 추출), LPC Coefficient(선형 예측 계수), Wavelet Transform(웨이블릿 변환), Neural Network(신경회로망), Rotating Machine(회전 기계)

ABSTRACT

As rotating machines play an important role in industrial applications such as aeronautical, naval and automotive industries, many researchers have developed various condition monitoring system and fault diagnosis system by applying various techniques such as signal processing and pattern recognition. Recently, fault diagnosis systems using artificial neural network have been proposed. For effective fault diagnosis, this paper used MLP(multi-layer perceptron) network which is widely used in pattern classification. Since using obtained signals without preprocessing as inputs of neural network can decrease performance of fault classification, it is very important to extract significant features of captured signals and to apply suitable features into diagnosis system according to the kinds of obtained signals. Therefore, this paper proposes the decision method of the proper feature vectors about each fault signal for neural-network-based fault diagnosis system. We applied LPC coefficients, maximum magnitudes of each spectral section in FFT and RMS(root mean square) and variance of wavelet coefficients as feature vectors and selected appropriate feature vectors as comparing error ratios of fault diagnosis for sound, vibration and current fault signals. From experiment results, LPC coefficients and maximum magnitudes of each spectral section showed 100 % diagnosis ratios for each fault and the method using wavelet coefficients had noise-robust characteristic.

1. 서 론

회전기계는 항공산업, 조선업, 자동차 산업 등의 산업현장에서 중요한 역할을 하고 있다. 이러한 회전기기가 오 동작을 일으키면 기계 자체에 영향을

줄 뿐 아니라 전체 공정의 중단 등 막대한 경제적 손실과 인명피해를 유발 할 수 있다⁽¹⁻³⁾. 이러한 이유로 최근에는 고장 진단 및 감시 시스템의 개발이 매우 중요한 문제로 대두되었다. 진단 시스템의 주요 목적은 고장이 발생했을 때 기술자들이 기계의 어느 부분을 분해해야 할지 알려주는 것과 내부 부품의 상태를 적절하게 분석하여 실시간 감시를 가능하게 하는 것이다⁽⁴⁾.

기계의 운전 상태를 점검하는 지표로는 온도, 음향, 사운드, 전류 등이 있다. 기어 시스템 등에서 고

† 교신저자; 정희원, 울산대학교 컴퓨터정보통신공학부
E-mail : upchong@ulsan.ac.kr

Tel : (052)259-2220, Fax : (052)258-1687

* 울산대학교 대학원 컴퓨터정보통신공학과

** 울산대학교 전기전자정보시스템공학부

장 진단에 음향 신호 분석을 사용하기도 하지만 일반적으로 기계의 상태를 나타내는 포괄적인 지표로는 진동 신호가 가장 널리 이용된다⁵⁾. 진동 신호의 에너지 크기는 기계의 상태와 직접적인 상관관계가 있어 에너지를 통해 기계의 상태를 평가할 수 있지만 고장의 기준이 되는 명확한 임계값(threshold)을 부품마다 정의해야 하는 어려움이 있다. 따라서 기계의 상태 진단은 제한적인 상황에서 추출된 파라미터들의 비교에 의해서 가능하다. 이러한 진동 신호에는 각각의 고장 성분들이 포함되어 있지만 고장의 특징을 반영한 파라미터들은 대부분 숨겨져 있기 때문에 취득 데이터를 고장 진단에 직접적으로 이용하기에 어려움이 있다. 신호의 변조(signal modulation), 잡음(noise), 높은 공진주파수(high frequency resonance)와 같이 취득된 신호를 비결정적(non-deterministic)이고 비정상 상태(non-stationary)로 만드는 환경 또한 고장 진단을 어렵게 만드는 요소이다. 그러므로 취득된 신호로부터 고장의 특징을 정확하게 추출하는 방법과 이를 효과적으로 분류하는 기술이 고장 진단 시스템에 있어 매우 중요하다⁴⁻⁶⁾.

고장을 진단함에 있어서 취득된 데이터의 해석과 판단은 순전히 전문가에 의존할 수 밖에 없었다⁴⁾. 이에 연구자들은 고장 데이터를 쉽게 분석하고 진단할 수 있는 고장 진단 시스템 개발에 많은 노력을 해왔다. 이리하여 초창기에 전문가 시스템(expert system) 모델이 탄생하였다. 규칙기반 전문가 시스템(rule-based expert systems)으로 알려진 이 시스템은 전문가의 지식과 경험을 퍼지이론과 if/then 구조를 이용하여 규칙으로 만들어 정량화 하였다^{1,2)}. 이로써 시스템이 전문가 없이도 제한적으로 데이터를 해석할 수 있게 되었다. 하지만 규칙 기반 전문가 시스템은 고정된 규칙으로 인한 병목(bottleneck)현상과 지식의 수정 및 추가의 어려움으로 단순한 소규모의 작업환경에만 적용 하였다⁵⁾. 또한 정상 및 비정상 데이터에 대한 데이터베이스를 만들어 상관관계를 비교하는 고장 진단 시스템도 제안 되었다^{13,17)}. 이 시스템은 데이터베이스 선정과 판별의 기준이 되는 임계값 설정에 대한 문제와 고장 유형이 많아 질수록 데이터베이스와 비교 연산이 많아지는 문제점을 가진다. 이러한 제한 사항을 해결하기 위해 인공 신경망 모델을 고장 진단 시스템에 적용하는 연구가 진행되기 시작하였다. 신경회로망의 장점은 학

습을 통해 최적화된 분류 모델을 만들어 전문가 시스템의 단점을 극복 할 수 있다는 것과 학습이 완료된 후에는 계산속도가 매우 빠르기 때문에 실시간 시스템에 적용시킬 수 있다는 것이다^{10,11)}. 이 논문에서는 주어진 각기 다른 고장 데이터를 효과적으로 분류하는 것이 목적이기 때문에 교사 학습(supervised learning)이 고장 진단 시스템에 적절하다고 판단하여 신호 처리, 음성 인식 및 음성 합성 등 다양한 분야에 응용되고 있는 MLP 신경회로망을 사용하였다¹¹⁾.

취득된 신호는 고장별 고유의 패턴과 관계없는 불필요한 데이터를 포함하고 있다. 이 데이터는 학습시에 신경회로망이 패턴을 구분하는데 방해되는 노이즈가 될 가능성이 크다¹¹⁾. 그러므로 신경회로망의 구성에 있어서 신호 처리 기술을 이용하여 신호를 분석하고 분석된 신호를 뚜렷하게 구분시켜 줄 특징 벡터 추출 방법이 주된 화제이다^{5,10)}. 이 논문은 기존에 제안된 신경회로망 기반 고장 진단 시스템이 가지는 특징 벡터의 제한점을 개선하기 위하여 특징 벡터로 LPC(linear predictive coding) 계수, 스펙트럼 구간별 최대값, 이산 웨이블릿 변환(discrete wavelet transform)의 대역 별 실효값과 분산을 제안한다. 또한 제안한 특징 벡터의 적절성을 판단하기 위하여 각기 다른 유도전동기에서 취득한 사운드, 진동, 전류 신호로부터 세 종류의 특징 벡터를 추출하였고 각각의 고장 신호에 대한 분류 결과에 따라 적합한 특징 벡터를 판단하였다.

이 논문의 구성은 다음과 같다. 2장에서는 신호처리 기술을 이용하여 특징벡터를 추출하는 기존의 연구에 대해 소개한다. 3장에서는 전체적인 고장 진단 시스템 소개한다. 고장 진단에 사용될 사운드, 진동, 전류 신호와 앞서 언급한 세 범주의 신호 분석방법에 의한 특징 추출 알고리즘에 대해서 설명한다. 또한 MLP 신경회로망에 대한 설명과 구성방법에 대해서 설명한다. 4장은 고장 진단 결과를, 마지막 장에서는 결론과 향후 과제에 대해서 요약한다.

2. 기존 연구

기계 고장 진단 및 예측 시스템에서 특징을 추출하기 위해서는 취득 신호를 분석하는 신호 처리 기술이 선행되어야 한다⁵⁾. 신호 처리 기술은 크게 시간 영역 분석, 주파수 영역 분석, 시간-주파수 분석

으로 분류 되고 각 영역 별로 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^(12,13). 주파수 영역 분석에는 푸리에 변환과 힐버트 변환을 대표적으로 사용하며, 이를 기반으로 주파수 평균 기법(frequency averaging technique), 적응 잡음제거(adaptive noise cancellation), 고 진동수 공진기법(high frequency resonance technique), 포락선(envelope) 분석 등이 제안되었다^(14,15). 시간-주파수 분석에는 비선형적이고 비정상상태의 신호를 분석하는데 용이한 STFT(short-time Fourier transform), Wigner-Ville distribution, Choi-Williams distribution, 웨이블릿 변환 등이 제안되었다^(6,16-18). 앞서 제안되었던 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⁽¹²⁾과 FFT의 N-point를 조절하는 방법⁽¹⁹⁾과 이산 웨이블릿의 대역별 통계치를 이용하는 방법이다^(7,8,20).

이 논문은 기존 모델이 제안했던 세가지 특징 벡터 추출 방법이 가지는 제한점을 제시하고 각각의 문제점을 개선하기 위하여 다음과 같이 세가지 특징벡터 추출 방법을 제안한다. 첫 번째, AR 모델의 잔여신호를 특징벡터로 이용하는 경우 잔여신호의 안정성은 있지만 여전히 각 고장간의 잔여신호의 임계값 설정의 문제를 남기고 있다. 이 논문에서는 확실한 파라미터 추출을 위해 AR 모델의 한 종류인 LPC 분석방법에서 추정된 LPC 계수를 특징벡

터로 제안한다. 두 번째, FFT 계수 전체를 신경회로망의 입력으로 적용시킬 때 N-point를 조절하여 입력 벡터를 조정해야 하지만 N-point를 줄임에 따라 주요 주파수 피크 성분이 손실 되는 가능성이 있다. 이 논문에서는 주요 피크값을 최대한 보존하기 위하여 N-point는 유지하되 구간을 나누어 각 구간별 최대값을 모아 특징벡터로 만드는 방법을 제안한다. 마지막으로 이산 웨이블릿 대역별 표준편차와 실효값과 분산 각각 특징벡터로 제안되었고 높은 고장 진단율을 나타내었다. 이 논문에서는 좀더 정확한 특징벡터를 추출하기 위하여 실효값과 분산을 동시에 특징벡터로 제안한다.

3. 고장 진단 시스템

이 논문에서의 전체적인 고장 진단 절차는 Fig. 1과 같다. 신경회로망 기반의 진단 시스템에 적절한 특징벡터를 선정하기 위하여 각기 다른 유도 전동기로부터 사운드, 진동, 전류 신호를 취득하였다. 취득된 신호로부터 고장 분류 성능을 극대화하기 위하여 신경회로망의 크기를 최적화 하면서 고장 신호별로 뚜렷하게 구별되는 특징 벡터를 시간 영역 분석, 주파수 영역분석, 시간-주파수 분석을 통하여 추출하였다. 추출된 특징벡터는 MLP 신경회로망을 통하여 학습되고 분류된다.

3.1 실험 데이터

(1) 사운드

모터 회전수를 달리하여(500, 1000, 2000, 3000 RPM) 서로 다른 고장에 대한 데이터를 취득하였

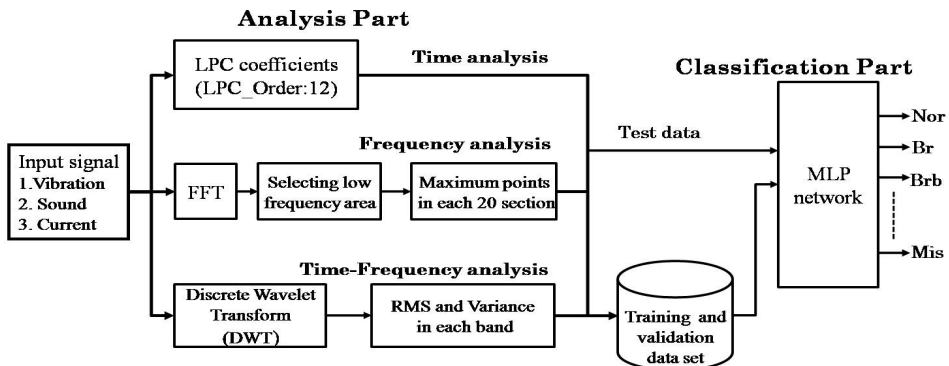


Fig. 1 Overall fault diagnosis system

다. 취득 데이터의 샘플링 주파수는 25.6 kHz, 데이터의 종류는 정상(normal, Nor), 베어링 결함(faulty bearing, Fbr), 볼트 불균형(bolt unbalance, Bo), 정렬불량(misalignment, Mis), 베어링 불평형(bearing unbalance, Un)으로 모두 5가지이다. 각각의 회전수에 대하여 고속 푸리에 변환(FFT)과 Wigner 방법으로 분석한 결과 2000 RPM에서 취득한 데이터가 고장 유형별로 가장 두드러진 특성을 나타내었다⁽⁷⁾. 이 논문에서는 2000 RPM의 데이터를 이용하였고 학습과 테스트를 위한 충분한 데이터 집합(data set)을 만들기 위하여 취득 데이터를 1초 길이의 프레임으로 나누어 각 상태별로 100개의 데이터를 추출하여 사용하였다.

(2) 진동

진동 데이터는 부경대학교 지능기계연구실에서 제공한 것으로⁽²⁰⁾, 6개의 유도전동기(0.5 kW, 60 Hz, 4극)에 각각 정상 데이터와, 정렬불량, 베어링 결함, 회전봉 불균형(broken rotor bar, Brb), 굽은 회전축(bowed rotor shaft, Br), 회전자 불평형(rotor unbalance, Run) 고장 데이터를 인위적으로 발생시켜 취득한 데이터이다. 샘플링 주파수는 8 kHz이며, 학습과 테스트를 위한 충분한 데이터 집합(data set)을 만들기 위하여 취득 데이터를 2.1333초 길이의 프레임으로 나누어 각 상태별로 100개의 데이터를 추출하여 사용하였다.

(3) 전류

유도전동기의 실험에 사용된 전류 데이터는 한국 디지털컨트롤(Korea Digital Control)사에서 제작한 MCSA(motor current signature analysis) 시뮬레이터를 이용하여 인위적으로 고장을 발생시킨 후 데이터를 취득하였다. 취득한 데이터는 정상, 정렬 불량, 베어링 결함, 회전봉 불균형, 굽은 회전축, 회전자 불평형 6가지이다. 샘플링 주파수는 24 kHz이며, 학습과 테스트를 위한 충분한 데이터 집합(data set)을 만들기 위하여 취득 데이터를 0.5초 길이의 프레임으로 나누어 각 상태별로 100개의 데이터를 추출하여 사용하였다.

3.2 특징 추출 알고리즘

취득한 입력 신호에는 고장별 고유의 패턴과 관

계없는 성분을 포함하고 있어 신경회로망의 입력 신호를 뚜렷하게 구별할 특징 벡터 추출 과정이 필요하다. 이러한 특징 벡터를 사용함으로써 분류 성능을 향상시킬 수 있다⁽¹¹⁾. 이 절에서는 신경회로망의 분류 성능을 극대화하기 위하여 고장 별 특징 벡터를 시간 영역, 주파수 영역, 시간-주파수 영역 분석 방법을 통하여 특징을 추출하는 방법을 기술한다.

(1) 시간 영역 분석

LPC는 사람의 발성기관을 하나의 필터로 간주하고 현재 파형은 현재 파형의 과거 값과 가중치의 곱을 합하여 추정될 수 있다는 것을 가정으로 한다. 성도 전달 특성 필터는 전극 모델을 사용하여 식 (1)과 같이 차분 방정식의 형태로 나타낼 수 있다. 여기서 $x(n)$ 과 $s(n)$ 은 입력 신호와 출력 신호이며, p 와 G 는 LPC 차수와 입력 신호의 가중치이다. 현재 신호와 과거 신호의 누적 된 추정치의 오차는 식 (2)와 같다. 여기서 추정 오차 $e(n)$ 를 최소로 하기 위하여 α 에 대해서 편미분하여 p 개의 연립방정식을 얻을 수 있다. 이는 Durbin 알고리즘으로 p 개의 α_j 를 구할 수 있다. 여기서 α_j 를 LPC 계수라고 정의한다⁽²¹⁾.

Table 1 LPC coefficients of vibration signals

Coeff. (ak)	Br	Brb	Fbr	Nor	Mis	Run
1	0.3324	-0.7790	-0.1999	-0.8031	-1.1967	-0.7700
2	0.0263	-0.3104	-0.5509	-0.3327	-0.0647	-0.3303
3	0.1121	0.2480	0.5640	0.2569	0.4335	0.1056
4	-0.0842	0.0831	0.2362	0.0197	0.2162	0.0499
5	-0.4638	-0.4163	0.6905	-0.4438	-0.4356	-0.4440
6	-0.3489	-0.2006	-0.0393	-0.0147	0.0007	-0.0051
7	-0.1860	0.5903	0.4410	0.4160	0.3673	0.4870
8	-0.0811	-0.0696	-0.2843	0.1406	-0.1662	0.0368
9	0.1716	-0.1140	-0.1345	-0.1925	-0.1172	0.0315
10	0.1345	0.0697	0.2487	0.0068	0.1380	-0.0610
11	-0.0491	-0.0281	-0.0569	0.0207	-0.6198	-0.0373
12	-0.0394	0.0324	-0.1318	-0.0140	-0.0080	-0.0272

$$s(n) = Gx(n) + \sum_{j=1}^p a_j s(n-j) \quad (1)$$

$$e(n) = s(n) - \sum_{j=1}^p \alpha_j s(n-j) \quad (2)$$

이 논문에서는 각 고장별 신호의 특징 벡터를 추출하기 위하여 LPC 계수를 이용하였다. LPC 필터 차수가 12 이상일 때 예측 이득이 크게 증가하지 않은 것으로 밝혀져⁽²²⁾ 이 논문에서는 LPC 필터 차수를 12로 하여 특징 벡터를 추출하였다. Table 1은 고장별 진동 신호에 대한 특징 벡터로 12개의 LPC 계수를 나타낸 것이다.

(2) 주파수 영역 분석

Fig. 2에서 진동 신호의 주파수 대역별 신호의 에너지 분포를 보면 입력 신호의 대부분의 고장 신호의 에너지 분포가 1 kHz 미만의 저주파 대역에 밀집한 것을 확인할 수 있다. 그러므로 이 논문에서는 특징 벡터를 추출하는데 500 Hz 이하의 데이터면 충분하다고 판단하여 500 Hz 이하의 데이터를 분석하여 주파수 축을 N개의 영역으로 나누어 각 영역의 최대값을 특징 벡터로 추출하였다. 신경회로망의 크기의 최적화와 정확한 고장분류를 동시에 만족하는 N을 찾기 위하여 실험을 하였고 N이 20임을 확인하였다. Fig. 3은 고장별 진동 신호의 주파수 구간별 최대값 20개를 특징 벡터로 나타낸 것이다.

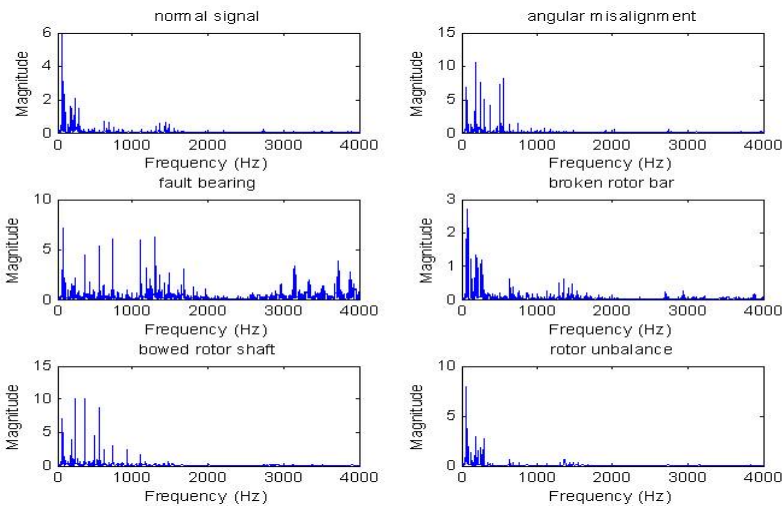


Fig. 2 Vibration signals in frequency domain

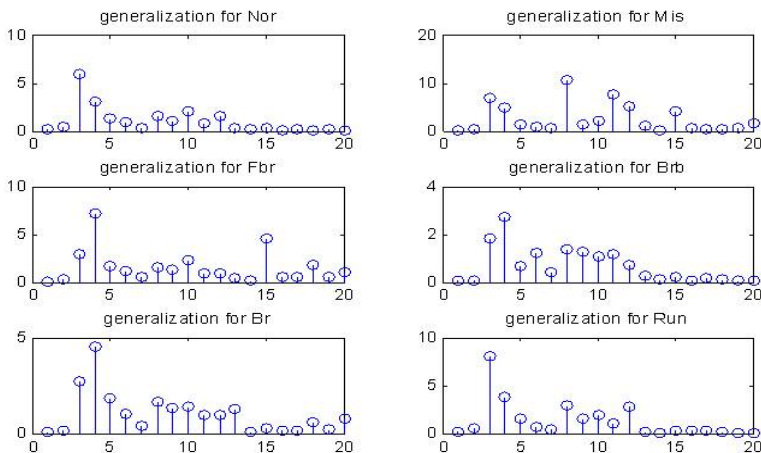


Fig. 3 Extracted feature vectors for vibration signals

(3) 시간-주파수 분석

이산 웨이블릿 변환을 이용한 다해상도 분석(multi-resolution analysis)은 저역 통과 필터와 고역 통과 필터의 계층적 필터뱅크로 구현되어 신호를 주파수 대역 별로 좀더 세밀하게 표현할 수 있다^(6,16).

이산 웨이블릿 변환을 이용한 고장 진단 시스템에서 신호의 특징 벡터를 추출하기 위해 대역별로 실효값, 표준편차, 분산이 적절한 특징 벡터로 제안되었다^(8,20). 이 논문에서는 각각의 고장신호에 대해 Daubechies 웨이블릿 8차를 이용하여 4레벨, 5개 대역의 신호로 분해하였고 최고주파 대역을 제외한 4개의 대역에서 실효값과 분산을 구하여 총 8개의 값을 신경회로망의 입력으로 사용하였다. Table 2는 이산 웨이블릿 변환을 이용하여 진동 신호의 고장별 4개의 대역에서 실효값과 분산으로 특징 벡터를 나타낸 것이다. 여기서 A1, D1, D2, D3의 대역은 0~0.5 kHz, 0.5~1 kHz, 1~2 kHz, 2~4 kHz이다.

3.3 MLP 신경회로망

고장 진단 시스템에 사용될 MLP 신경회로망은 교사학습(supervised learning)의 한 종류로 음성인식, 단백질 구조분석, 수중음파의 분석 등 광범위한 분야에 응용 되어왔으며 다른 신경회로망 분류기와 비교 했을 때에 상대적으로 메모리 요구량이 적은 장점을 가지고 있다⁽¹⁰⁾. MLP 신경회로망의 구성은 입력 층(input layer), 은닉 층(hidden layer), 출력 층(output layer)으로 구성되며 각각의 뉴런은 완전 연결(fully connected) 되어있다. MLP의 절차는 피드포워드(feed-forward) 과정과 역전파(back propagation) 과정을 통해 연결강도(connection weight)를

조절하고, 계산된 결과 값과 목표 값(target value)과의 에러를 최소화함으로써 학습 모델을 최적화한다⁽⁹⁾.

은닉 층의 뉴런은 학습을 통해 점진적으로 발견되는 특징을 찾아내는데 중요한 역할을 하기 때문에 은닉 층의 개수와 크기를 설정하는 문제는 신경회로망의 성능을 좌우하는 매우 중요한 부분이다. 또한 은닉 층 뉴런 개수는 해결하고자 하는 문제에 따라 뉴런 개수의 최적화가 달라지기 때문에 시스템에 맞게 적절한 은닉 뉴런 개수를 선정해야 한다⁽¹¹⁾. 이 논문에서는 신경회로망의 크기를 최적화하기 위해 은닉 층의 개수를 범용 근사화 이론(universal approximation)에 따라 1개로 설정하였다. MLP 신경망을 구성하는데 있어서 은닉 층의 뉴런 개수를 10개부터 3개까지 줄여가면서 실험하였고 그 결과 은닉 층의 뉴런 개수가 5개 이하부터는 분류 성능이 점점 줄어드는 것을 확인하였다. 그러므로 이 논문에서는 신경회로망의 크기의 최적화와 고장 분류 성능의 극대화를 동시에 만족시키는 은닉 층의 뉴런 개수를 6개로 결정하였다. 학습 알고리즘(learning algorithm)은 비교적 성능이 뛰어나다고 알려진 scaled conjugated gradient 알고리즘을 이용하였고 정확한 결과를 얻었다⁽²³⁾. 학습 정도는 학습 횟수(epochs)보다 표준오차평균(MSE: mean squared error)를 우선으로 하여 학습 임계값을 1.00E-05로 정하였다. 또한 300번 이상의 학습에도 불구하고 수렴하지 못하면 자동으로 학습 종료를 시켰다. 분석에 사용된 MLP 신경회로망의 설정 값은 Table 3과 같다.

학습과 테스트를 위한 데이터 설정은 특징 추출 알고리즘으로부터 추출한 특징 벡터의 70%를 학습 데이터로 30%를 테스트 데이터로 나누었고 최상의 학습 모델 선정과 학습 과정에서 조기 중단(early stopping)을 결정하기 위해 학습 데이터 집합의 하위

Table 2 Feature vectors for vibration signals using DWT (unit : 10⁻⁴)

	Br	Brb	Fbr	Nor	Mis	Run
A1_rms	2.10	1.54	2.72	2.26	4.69	3.21
D1_rms	0.896	0.586	1.67	0.742	3.47	0.795
D2_rms	0.611	0.162	1.15	0.159	1.59	0.168
D3_rms	1.06	0.0942	0.801	0.103	0.305	0.103
A1_var	0.457	0.245	0.764	0.0764	2.27	1.06
D1_var	0.0827	0.0353	0.288	0.0288	1.21	0.065
D2_var	0.0767	0.00538	0.271	0.00522	0.517	0.00582
D3_var	0.0461	0.00364	0.264	0.00434	0.0381	0.00437

Table 3 Parameters of MLP neural network

Parameters	Configuration
Learning algorithm	Scaled conjugate gradients
Learning rate	0.05
Transfer function	Tangent sigmoid
Training method	Batch training
Performance function	MSE(mean squared errors)

집합인 모델을 검증하는 데이터 집합을 나누었다. 제안한 시스템에서는 Kearns의 권장사항으로 학습 데이터의 20%를 검증을 위한 데이터로 나누었다⁽¹¹⁾. 또한 MLP 신경회로망이 새롭게 초기화 되면서 가중치(weight) 역시 -1에서 1사이의 값으로 무작위로 초기화되고 학습 데이터 집합의 선정에 따라서 매번 학습할 때마다 다른 신경회로망 모델이 만들어진다. 이 논문에서는 학습 데이터 집합을 달리하면서 학습시켜 최적의 신경회로망을 선택하였다. 이 논문에서 MLP 신경회로망 설계 및 학습은 MathWorks사의 Matlab 7.6.0에서 Neural Network Toolbox를 이용하였다.

4. 실험 결과

제안한 알고리즘에 의해 추출된 각각의 특징 벡터의 고장 분류 성능을 판단하기 위해서 사운드, 진동, 전류 신호를 사용하였다. 사운드, 진동, 전류 신호에 대해 각각 100개의 데이터를 생성하여 데이터의 70%를 학습 데이터로 나머지 30%를 테스트 데이터로 만들어 학습과 검증의 과정을 거쳐 분류를 수행하였다. Fig. 4는 사운드, 진동, 전류의 각각의 고장 데이터에 대해 세가지 특징 추출 방법을 적용한 고장 분류 오차율을 나타낸다.

Fig. 4로부터 LPC 계수와 스펙트럼 구간별 최대값을 특징 벡터로 사용하였을 때 사운드, 진동, 전류 데이터에 대해서 고장 유형별로 100% 분류가 되었다. 반면 웨이블릿 계수의 실효값과 분산을 특징 벡터로 하였을 경우 사운드와 진동 데이터에 대해서는 100%의 분류 결과를 보였지만 전류 데이터의 경우에 특히 베어링 결함과 정렬 불량에 각각 87%, 91%의 분류 결과를 나타내었다. 이는 각 고장에 대한 전류 신호의 스펙트럼이 60 Hz 부근에 대부분의 에너지가 집중되어 4개의 대역 중 최저주파 대역(0 Hz~1.5 kHz)을 제외한 나머지 대역에서 6개의 실효값과 분산이 각각의 고장을 구별 짓기에 충분한 역할을 하지 못한 것으로 판단된다.

전류 데이터와 달리 사운드와 진동 데이터를 실제 산업현장에서 취득시 주변 잡음이 포함될 가능성이 크다. 따라서 이 논문에서는 취득한 각 고장 데이터의 테스트 집합에 백색 잡음을 추가하여 고장 분류 성능을 평가하는 실험을 하였다. 그리하여

원 신호와 잡음을 추가한 신호와의 SNR을 30, 20, 10, 5 dB로 달리하면서 제안한 특징 벡터들이 추가된 잡음에 얼마나 강인한지 평가하였다. Fig. 5는 잡음이 추가된 사운드와 진동 데이터에 대한 세가지 특징 벡터들의 고장 분류 오차율을 나타내었다. 웨이블릿 계수의 실효값과 분산은 백색잡음이 추가된 상황에서도 100% 분류되어 잡음에 매우 강인한 특성을 보였다. 그러므로 전류 데이터를 제외한 사운드와 진동 데이터로부터 웨이블릿을 이용하여 특징 벡터를 추출하였을 경우 이를 진단 시스템에 직접적으로 적용할 수 있는 장점이 있다. 스펙트럼 구간별 최대값은 이상적인 상태에서 취득된 각각의 사운드, 진동, 전류 고장데이터를 모두 분류 하였지만 백색잡음 추가 실험에서 원 신호와의 SNR이 10dB 이하일 경우에 분류율이 점차 줄어드는 것을 확인하였다. 이를 이용한 특징 벡터는 전류 고장 데이터 진단에 적합하고 진동 데이터에 적용 시에는 신호 취득의 정확성이 요구되거나 특징 벡터 추출 전에 잡음 제거 과정이 필요하다. LPC 계수의 경우에는

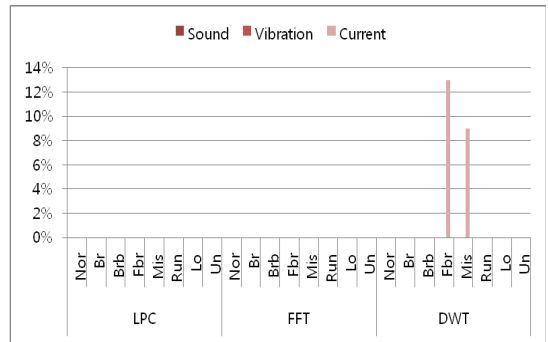


Fig. 4 Error rates of classification for each feature

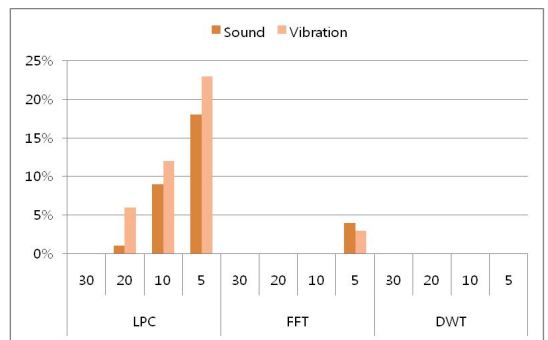


Fig. 5 Error rates of classification after adding noise

백색잡음이 더해진 환경에서 사운드와 진동 데이터 대해서 각각 82.5%, 77%의 분류결과를 보여 LPC 계수가 잡음에 가장 민감한 것으로 확인되었다. 그러므로 고장 진단 시스템의 특징 벡터로 LPC 계수를 실제 산업현장에 적용 시에 스펙트럼을 이용한 특징 추출 방법보다 정밀한 신호 취득이 요구되고 보다 강력한 잡음 제거 과정이 필요하다.

5. 결 론

이 논문은 MLP 신경회로망을 이용한 회전기계의 고장 진단 시스템에서 서로 다른 고장 신호에 대한 적절한 특징 벡터를 결정하는 방법을 제안하였다. 사용한 특징 추출 알고리즘은 LPC 계수, 스펙트럼 구간별 최대값, 대역별 웨이블릿 계수들의 실효값과 분산을 구하는 것이며, 이들을 특징 벡터로 이용하여 MLP 신경회로망의 학습 및 테스트 데이터로 활용하였다. 각각의 특징 벡터들을 이용하여 사운드, 진동, 전류신호에서 취득한 각기 다른 고장 데이터에 대해서 고장 분류 성능을 평가하였다.

진단시스템에 적용된 특징 벡터는 적은 파라미터를 가지고도 사운드, 진동, 전류신호에 대해 모두 높은 진단율을 보였다. 구체적으로 웨이블릿 계수를 이용한 특징 벡터는 잡음이 섞여있는 환경에 매우 강인하여 사운드와 진동신호의 특징 벡터로 적합하였다. LPC 계수와 스펙트럼을 이용한 방법은 사운드, 진동, 전류 신호에 대한 고장 진단 시스템의 특징 벡터로 모두 적합하였지만 잡음이 추가되었을 경우에는 고장 진단에 영향을 주었다. 특히 LPC 계수는 잡음에 매우 취약하여 산업현장에 적용할 때 신호 취득의 정밀함과 잡음 제거 과정이 요구된다.

이 논문에서 사용된 고장 진단 시스템은 세가지 각기 다른 기계에서 취득한 신호를 이용하였지만 실시간 고장 진단 시스템으로 발전시켜 실제 산업현장에 적용시켜야 할 것이다. 또한 이 논문에서 다룬 고장 진단 시스템은 한가지 고장이 발생했을 경우에 대해서만 진단하는 것을 기본전제로 한다. 그러므로 실제 현장에서 여러 고장이 복합적으로 일어나는 환경에 적용하기에는 많은 어려움이 있다. 향후에는 이런 복합적으로 발생하는 고장에 대해서도 원인을 알아낼 수 있는 연구가 이루어져야 할 것이다.

참 고 문 헌

- (1) Chow, M.-Y., Sharpe, R. N. and Hung, J. C., 1993, "On the Application and Design of Artificial Neural Networks for Motor Fault Detection - Part I," IEEE Transactions On Industrial Electronics, Vol. 40, No. 2, pp. 181~188.
- (2) Goode, P. V. and Chow, M.-Y., 1995, "Using a Neural/Fuzzy System to Extract Heuristic Knowledge of Incipient Faults in Induction Motors: Part I - Methodology," IEEE Transactions On Industrial Electronics, Vol. 42, No. 2, pp. 131~138.
- (3) Sanz, J., Perera, R. and Huerta, C., 2007, "Fault Diagnosis of Rotating Machinery Based on Auto-associative Neural Networks and Wavelet Transforms," Journal of Sound and Vibration, pp. 981~999.
- (4) Crupi, V., Guglielmino, E. and Milazzo, G., 2004, "Neural-network-based System for Novel Fault Detection in Rotating Machinery," Journal of Vibration and Control, Vol. 10, pp. 1137~1150.
- (5) Li, F., Meng, G., Ye, L. and Chen, P., 2008, "Wavelet Transform-based Higher-order Statistics for Fault Diagnosis in Rolling Element Bearings," Journal of Vibration and Control, Vol. 14, No. 11, pp. 1691~1709.
- (6) Li, F., Meng, G., Ye, L. and Chen, P., 2005, "Feature Extraction with Discrete Wavelet Transform for Drill Wear Monitoring," Journal of Vibration and Control, Vol. 11, No. 11, pp. 1375~1390.
- (7) Tuan, D. V., 2009, "Fault Detection and Diagnosis for Induction Motors using Local Feature, Variance, Cross-correlation and Wavelet," Ph.D Dissertation in University of Ulsan.
- (8) Chong, U.-P., Cho, S.-J. and Lee, J.-Y., 2006, "Fault Diagnosis for Rotating Machine Using Feature Extraction and Minimum Detection Error Algorithm," Transactions of the Korean Society for Noise and Vibration Engineering, Vol. 16, No. 1, pp. 23~33.
- (9) Basheer, I. A. and Hajmeer, M., 2000, "Artificial Neural Network: Fundamentals,

Computing Design, and Application,” *Journal of Microbiological Methods*, Vol. 43, pp. 3~31.

(10) Lippmann, R. P., 1989, “Pattern Classification Using Neural Network,” *IEEE Communication Magazine*.

(11) Haykin, S., 1999, “Neural Networks: A Comprehensive Foundation,” Prentice-Hall, New Jersey, pp. 156~248.

(12) Baillie, D. C. and Mathew, J., 1995, “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.

(13) Thanagasundram, S. and Schlindwein, F. S., 2006, “Autoregressive Based Diagnostics Scheme for Detection of Bearing Faults,” *Proceedings of ISMA2006 Noise and Vibration Engineering Conference*, pp. 3531~3546.

(14) Ocak, H. and Loparo, K. A., 2004, “Estimation of the Running Speed and Bearing Defect Frequencies of an Induction Motor from Vibration Data,” *Mechanical Systems and Signal Processing*, Vol. 18, pp. 515~533.

(15) McFadden, P. D. and Smith, J. D., 1984, “Vibration Monitoring of Rolling Element Bearings by High Frequency Resonance Technique – A Review,” *Tribology International*, Vol. 77, pp. 3~10.

(16) Ge, M., Zhang, G. C. and Yu., Y., 2002, “Feature Extraction From Energy Distribution of Stamping Processes Using Wavelet Transform,” *Journal of Vibration and Control*, Vol. 8, pp. 1323~1032.

(17) Dung, L. and Mizukawa, M., 2007, “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

(18) Nelwamondo, F. V., Marwala, T. and Mahola, U., 2006, “Early Classifications of Bearing Faults Using Hidden Markov Models, Gaussian Mixture Models, Mel-frequency Cepstral Coefficients and Fractals,” *International Journal of Innovative Computing, Information and Control*, Vol. 2, No. 6, pp. 1281~1299.

(19) McFadden, P. D. and Smith, J. D., 1993, “Monitoring and Diagnosis of Rolling Element Bearing Using Artificial Neural Networks,” *IEEE Transactions on Industrial Electronics*, Vol. 40, No. 2, pp. 209~217.

(20) Yang, B.-S., Kim, K. J. and Han, T., 2004, “Fault Diagnosis of Induction Motors Using Data Fusion of Vibration and Current Signal,” *Transactions of the Korean Society for Noise and Vibration Engineering*, Vol. 14, No. 11, pp. 1091~1100.

(21) Markel, J. D. and Gray, Jr. A. H., 1976, “Linear Prediction of Speech,” Springer-Verlag, Berlin Heidelberg, New York.

(22) Kondoz, A. M., 1994, “Digital Speech Coding for Low Bit Rate Communication System,” John Wiley & Sons Ltd, pp. 36~50.

(23) Dreiseitl, S. and Ohno-Machado, L., 2002, “Logistic Regression and Artificial Neural Network Classification Models: a Methodology Review,” *Journal of Biomedical Informatics*, Vol. 35, pp. 352~359.