

# LPC와 DNN을 결합한 유도전동기 고장진단

류진원<sup>†</sup>, 박민수<sup>\*\*</sup>, 김남규<sup>\*\*\*</sup>, 정의필<sup>\*\*\*\*</sup>, 이정철<sup>\*\*\*\*\*</sup>

## Fault Diagnosis of Induction Motor using Linear Predictive Coding and Deep Neural Network

Jin Won Ryu<sup>†</sup>, Min Su Park<sup>\*\*</sup>, Nam Kyu Kim<sup>\*\*\*</sup>, Ui Pil Chong<sup>\*\*\*\*</sup>, Jung Chul Lee<sup>\*\*\*\*\*</sup>

### ABSTRACT

As the induction motor is the core production equipment of the industry, it is necessary to construct a fault prediction and diagnosis system through continuous monitoring. Many researches have been conducted on motor fault diagnosis algorithm based on signal processing techniques using Fourier transform, neural networks, and fuzzy inference techniques. In this paper, we propose a fault diagnosis method of induction motor using LPC and DNN. To evaluate the performance of the proposed method, the fault diagnosis was carried out using the vibration data of the induction motor in steady state and simulated various fault conditions. Experimental results show that the learning time of our proposed method and the conventional spectrum+DNN method is 139 seconds and 974 seconds each executed on the experimental PC, and our method reduces execution time by 1/8 compared with conventional method. And the success rate of the proposed method is 98.08%, which is similar to 99.54% of the conventional method.

**Key words:** Induction Motor, Diagnosis, Spectrum, LPC, DNN

### 1. 서 론

유도전동기는 중공업, 발전소 등 여러 산업체에 서 핵심적인 생산 장비로 사용되고 있다. 유도 전동 기를 공장에 설치할 시에 미세한 오차가 존재하거나 장기간 기계를 사용하게 되면 변형이 일어나거나 기 계 부품들의 마모가 생길 수 있다. 이러한 요인으로 부품들 간에 마찰 또는 충격이 발생하게 되고 기계 시스템에 복잡한 진동을 유발한다. 이는 기계의 성능

과 수명을 단축시키는 주요 요인이 된다[1]. 만약 유 도전동기에 고장이 발생한다면 해당 기계에 관련된 부가적인 기계들의 작동이 중지되어 막대한 경제적 손실을 일으킬 수 있다. 따라서 유도전동기의 지속적 인 모니터링을 통하여 고장을 예측하고 진단하는 시 스템 구축이 필요하다.

유도전동기의 운전 상태를 점검하는 지표로는 온 도, 진동, 음향 신호, 전류 신호 등이 있다. 이 중에서 진동 신호를 측정하여 유도전동기의 상태를 진단하

※ Corresponding Author: Jung Chul Lee, Address: (44610) Daehak-ro 93, Nam-gu, Ulsan, Korea, TEL: +82-52-259-1269, FAX: +82-52-259-1687, E-mail: jungclee@ulsan.ac.kr

Receipt date: Sep. 26, 2017, Revision date: Nov. 2, 2017  
Approval date: Nov. 15, 2017

<sup>†</sup> School of IT Convergence, University of Ulsan  
(E-mail: Alskdj666@naver.com)

<sup>\*\*</sup> School of IT Convergence, University of Ulsan  
(E-mail: pms4751@gmail.com)

<sup>\*\*\*</sup> School of IT Convergence, University of Ulsan  
(E-mail: knk0450@naver.com)

<sup>\*\*\*\*</sup> School of IT Convergence, University of Ulsan  
(E-mail: upchong@ulsan.ac.kr)

<sup>\*\*\*\*\*</sup> School of IT Convergence, University of Ulsan

※ This research was supported by the development project of IoT bi-directional sensing-decision and condition based maintenance and device monitoring system of Korea Industrial Complex Corporation (RND-16043)

는 방법이 많이 사용되고 있다[2]. 진동 신호의 에너지 크기는 기계의 상태와 직접적인 상관관계가 있어 에너지를 통해 기계의 상태를 평가할 수 있다. 하지만 고장의 특징을 반영한 파라미터들은 대부분 숨겨져 있기 때문에 취득 데이터를 직접 적용하여 고장 진단할 경우 정확도가 낮다. 신호의 변조(signal modulation), 잡음(noise), 높은 공진 주파수(high frequency resonance)와 같이 취득된 신호를 비결정적이고 비정상상태로 만드는 환경 또한 고장진단을 어렵게 만드는 요소이다. 그러므로 취득된 신호로부터 고장의 특징을 정확하게 추출하는 방법과 이를 효과적으로 분류하는 기술이 고장진단 시스템에 있어 매우 중요하다[3].

유도전동기의 고장 진단을 위해서는 계측, 데이터 수집, 데이터 분석 및 고장 진단으로 이루어진 시스템 구축이 필요하며 고장 신호의 특징을 추출하기 위해서는 취득 신호를 분석하는 신호 처리 기술이 선행되어야 한다[4]. 신호 처리 기술은 크게 시간 영역 분석, 주파수 영역 분석, 시간-주파수 영역 분석으로 분류되고 각 영역 별로 고장 진단 시스템에 적용된다. 시간 영역 분석에는 신호로부터 평균, 실효치, 표준편차, 분산, 왜도, 첨도와 같은 통계치를 분석하는 방법과 시계열 분석이 제안 되었고[5,6], 주파수 영역 분석에는 푸리에 변환과 힐버트 변환을 대표적으로 사용하여, 이를 기반으로 주파수 평균 기법, 적응 잡음 제거, 고 진동수 공진기법 등이 제안되었다[7]. 시간-주파수 분석에는 비선형적이고 비정상상태의 신호를 분석하는데 용이한 STFT(Short-Time Fourier Transform), 웨이블릿 변환 등이 제안 되었다[8,9,10,11]. 이러한 신호 처리 기법과 신경회로망,

퍼지 추론 기법 등을 결합한 진단 알고리즘에 대해서 국·내외적으로 많은 연구가 수행되고 있다[12]. 신경망 모델이 적용되지 않은 고장 진단 시스템에서는 데이터베이스 선정과 판별의 기준이 되는 임계값 설정에 대한 문제와 고장 유형이 많아질수록 데이터베이스와 비교 연산이 많아지는 문제점을 가진다. 따라서 최적화된 분류 모델을 만들 수 있고 학습이 완료된 후에는 계산속도가 매우 빠르다는 장점을 가진 신경망 모델을 고장 진단 시스템에 적용되고 있다.

본 논문에서는 신호 처리 기법중 하나인 LPC (Linear Predictive Coding) 분석과 기계 학습중의 하나인 DNN(Deep Neural Network)을 결합한 고장 진단 시스템을 제안한다. LPC는 음성신호 분석에서 사용되는 신호처리 기법으로, 이전입력, 이전출력, 현재입력을 적절히 선형 조합하여 새로운 출력을 예측하는 기술이다[13]. 제안된 방식의 성능 평가를 위해 유도전동기로부터 정상 및 모의 고장상태의 진동신호를 취득하여 실험에 사용하였다. 그리고 신호의 스펙트럼을 이용한 고장진단 실험결과와 본 논문에서 제안된 방식의 실험결과를 비교·분석하여 제안된 방식의 성능을 평가하였다. 그리고 신경 회로망의 은닉층 수, 노드 수에 따른 고장 진단의 성능 실험 결과도 제시하였다.

본 논문의 구성은 다음과 같다. 2장에서는 고장진단 모니터링 시스템 구성과 데이터 취득 방법 및 제안하는 고장신호 분류 알고리즘에 대하여 기술한다. 3장에서는 LPC 데이터를 사용한 DNN실험 결과를 설명한다. 마지막으로 4장에서는 LPC와 DNN을 이용한 고장진단 실험 결과에 대해 고찰한 후 결론을 맺는다.

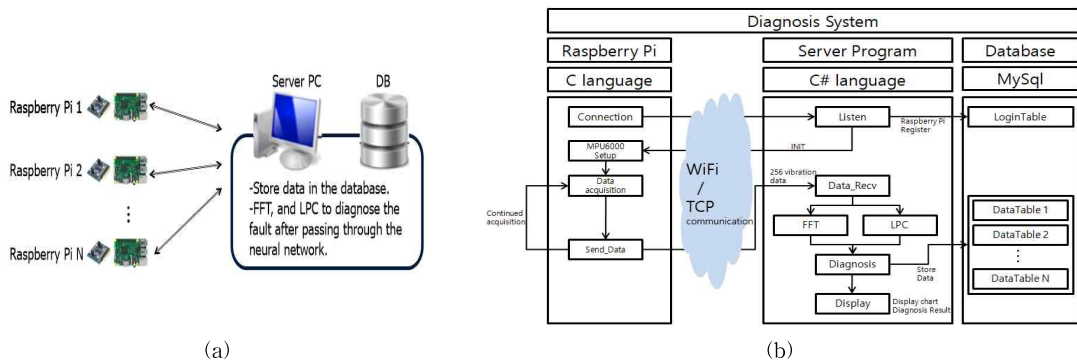


Fig. 1. Fault Diagnosis System Configuration.

## 2. 고장진단 시스템 구성 및 알고리즘

### 2.1 고장진단 시스템 구성

본 논문의 고장진단 시스템은 Fig. 1(a)와 같이 MPU 6000 가속도센서, 라즈베리파이, 서버용 PC, DB로 구성된다. 상용 임베디드 컴퓨터인 라즈베리파이 모듈은 서버로부터 제어신호를 받아 MPU6000 진동센서를 제어하여 유도전동기로부터 진동데이터를 실시간으로 수집하고, WiFi 무선통신으로 서버용 PC와 데이터를 송수신하는 기능을 수행한다. 라즈베리파이는 내부의 GPIO2, GPIO3핀을 사용하여 I2C 방식으로 MPU6000 가속도센서와 통신한다.

서버용 PC는 Fig. 1(b)와 같이 Listen 상태로 라즈베리파이가 연결요청이 올 때까지 대기한다. 연결 요청을 받으면 각 라즈베리파이마다 고유한 ID를 부여하고 DB에 라즈베리파이의 정보를 저장하고 관리한다. 그리고 라즈베리파이가 진동데이터를 수집할 수 있도록 가속도센서와 부가적인 기능을 초기화 할 수 있게 INIT 신호를 보내주고 라즈베리파이에서 진동데이터를 수신 받을 준비를 한다. 이후 라즈베리파이로부터 진동데이터를 수신 받으면 진동 데이터로부터 실시간으로 FFT 스펙트럼과 LP계수를 계산하고 DNN을 이용하여 고장진단을 수행한다. 그리고 진동데이터와 분석 결과를 모니터에 출력한 뒤, DB에 저장하고 관리한다.

본 논문에서 사용한 유도전동기 고장진단용 시뮬레이터는 국내의 DyLab사 MVS-100모델을 사용하였으며 세부사양은 다음과 같다. 전동기는 지멘스 3상 AC모터이고 최대 1800RPM까지 구동이 가능하며 전압은 구동입력 230VAC이다. 샤프트는 직경 17mm의 철이고, 각 베어링의 볼 수는 6개이다. 로터

디스크는 M6용 나사홀이 원주상에 2열로 각각 18개씩 뚫려있다. 시뮬레이터의 전체 무게는 60kg이며 가로 길이는 70cm, 폭은 31cm, 높이는 36cm이다. 시뮬레이터와 가속도센서의 부착방법은 Fig. 2(a), Fig. 2(b)와 같다.

### 2.2 정상상태와 모의 고장상태 진동데이터의 스펙트럼 분석

Fig. 2(a)의 유도전동기 고장진단 시뮬레이터를 이용하여 정상상태, 베어링 결함상태, 기계적 느슨함 상태, 불균형 상태, 축 정렬 불량 상태에 대한 5가지 유형의 진동 데이터를 수집하였고 각 유형에 대한 스펙트럼 특성을 분석하였다.

먼저 정상 상태(Normal state)의 진동 데이터는 유도 전동기에 아무런 결함이 없는 정상상태에서 수평을 맞추고 데이터를 10분간 취득하였다. Fig. 3(a)는 정상 상태의 회전축 진동 데이터에 대한 FFT스펙트럼과 LPC스펙트럼을 보여준다. 정상 상태에서는 0 Hz, 125 Hz, 150 Hz, 425 Hz 부근에서 높은 진폭의 신호가 검출되었다. 베어링 결함(Bearing Fault state) 데이터는 베어링에 홈이 파져 결함이 있는 베어링으로 교체 후 x축 진동 데이터를 10분간 취득하였다. Fig. 3(b)와 같이 베어링 결함 상태에서는 0 Hz, 125 Hz, 150 Hz 부근에서 높은 진폭의 신호가 검출되었다. 기계적 느슨함 상태(Looseness state) 데이터는 모터를 바닥에 고정하고 있는 나사 4개중 3개를 1바퀴 정도 느슨하게 푼 뒤 x축 진동 데이터를 10분간 취득하였다. Fig. 3(c)와 같이 기계적 느슨함 상태에서는 125, 150, 210Hz 부근에서 높은 진폭의 신호가 검출되었다. 불균형 상태(Unbalance state)는 회전체의 기하학적 중심축과 질량 중심이 일치하지 않




Fig. 2. (a) The whole appearance of the induction motor, (b) the sensor attached to the motor.




Fig. 3. FFT spectrum and LPC spectrum. (a) normal state, (b) bearing Fault state, (c) looseness state, (d) unbalance state, (e) misalignment state.

아 생기는 현상이다[13]. 유도전동기의 로터에 4.1g의 나사를 로터의 10도 위치에 부착하여 불균형 상태를 만들어 x축 진동 데이터를 10분간 취득하였다. Fig. 3(d)와 같이 불균형 상태에서는 25Hz 근처에서 특징 주파수가 검출 되었다. 축 정렬 불량 상태 (Misalignment state)는 회전 기계의 회전축의 정렬이 평행하지 않은 상태이다. 이는 모터의 축을 1mm 가량 틀고 x축 진동데이터를 10분간 취득하였다. Fig. 3(e)와 같이 축 정렬 불량 상태에서는 150, 200, 450Hz 부근에서 높은 진폭의 신호가 검출되었다.

### 2.3 고장진단 알고리즘

유도전동기의 고장 신호는 비선형, 시변의 특성을 가지므로 모델링하기가 쉽지 않다. 그러나 이러한 특징 데이터를 신경망에 적용하면 모델을 쉽게 구할 수 있다. 기계학습 중의 하나인 DNN은 여러 비선형 변환기법의 조합을 통해 높은 수준의 추상화를 시도하는 기계학습 알고리즘의 집합으로 정의된다. DNN은 입력층과 출력층 사이에 여러 개의 은닉층(Hidden

Layer)들로 이루어진 인공 신경망이다[14]. DNN은 일반적인 인공신경망과 마찬가지로 복잡한 비선형 관계들을 모델링 할 수 있다. DNN은 역전파 알고리즘으로 학습될 수 있다. 이 때, 가중치(Weight)들은 확률적 경사 하강법(Stochastic Gradient Descent)으로 갱신한다[14,15].

본 논문에서 사용되는 DNN 구조를 Fig. 4에 나타내었다. Fig. 4(a)와 같이 스펙트럼을 입력으로 사용하는 DNN 구조이고 Fig. 4(b)는 LP계수를 입력으로 사용하는 DNN 구조이다. 활성화수로는 은닉층에서는 ReLU, 출력층에서는 softmax를 사용하였으며 모멘텀을 추가해서 가중치를 갱신하였다. 입력층 노드의 수는 입력신호가 스펙트럼 데이터일 경우 128개, LP 계수일 경우는 20개로 구성된다. 스펙트럼 데이터는 256개의 진동데이터를 FFT 변환하고 절반인 128 포인터의 변환 결과의 크기 값을 계산하여 구하였다. 20차의 LP 계수는 Durbin 알고리즘을 이용하여 256개의 진동데이터로부터 추정하였다. 기본적으로 은닉층은 2개 층으로 구성되며, 각 은닉층의 노드

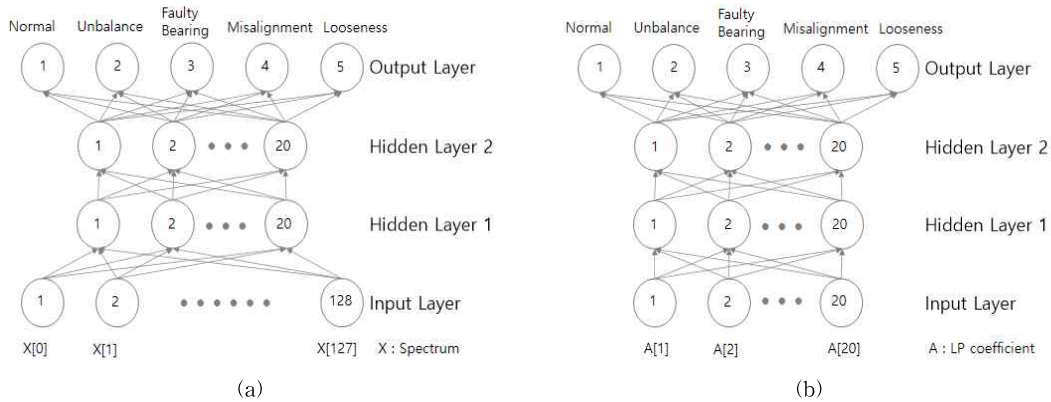


Fig. 4. Structure of the neural network, (a) spectrum+DNN training, (b) LPC+DNN training.

개수는 20개이고, 출력층의 노드 개수는 5가지 고장 범주에 맞춰 5개로 정하였다. 이상이 실험에 사용한 신경회로망의 기본 설정이며 세부 실험에서 상기 설정 값을 변경하며 성능변화를 관찰하였다.

### 3. 실험 결과

본 논문에서 제안한 유도전동기 고장진단 방식의 성능평가 실험에 사용한 데이터는 Fig. 2의 유도전동기 고장진단용 시뮬레이터와 가속도센서를 사용하여 수집하였다. 유도전동기를 고정된 바닥에 평형상태로 고정시키고 정상 상태, 베어링 결함 상태, 기계적 느슨함 상태, 불균형 상태, 축 정렬 불량 상태를 만들고서 각 상태별 진동데이터를 표본화 주파수 1 kHz, 16bit로 양자화 하였다. 유도전동기의 회전수는 RPM 1000, 1200, 1500의 3가지로 설정하였다. 상기 5가지 상태와 3가지 RPM 별로 각각 10분씩 모두 150분 분량의 진동데이터를 수집하였다. 수집정도를 확인하기 위해서 2500번 반복해서 신경망을 학습하였고 0.1의 학습률(Alpha), 활성화함수는 은닉층에서는 ReLU, 출력층에서는 softmax를 사용하였으며 모멘텀을 추가해서 가중치를 갱신하였다. 전체 36,000개 프레임의 진동데이터에서 60%를 학습용으로, 나머지 40%를 성능 평가용으로 사용하였다. 그리고 DNN의 과적합 문제를 해결하기 위해 전체를 다 학습시키지 않고 일부 노드만 무작위로 골라 학습시키는 드롭아웃(Dropout)기법을 적용하였다.

#### 3.1 은닉층 개수 증가에 따른 진단 정확률과 학습 소요 시간

2.3절에서 언급한 기본 신경망 설정을 기준으로 은닉층의 개수에 따른 진단 정확률 변화를 측정하였다. 기존의 학습방법에서는 학습용 데이터를 이용하여 반복학습 완료한 뒤, 학습된 최종 가중치를 평가용 데이터에 적용하여 성능을 평가를 한다. 본 실험에서는 기존 방식과 다르게 전체 데이터의 60%인 학습용 데이터로 매회 학습할 때마다 정확률 측정값은 변경된 가중치를 전체 데이터의 40%인 평가용 데이터에 적용하여 구하였다.

스펙트럼 입력벡터를 이용한 학습 회수별 진단 정확률을 Fig. 5(a)에, LPC 입력벡터의 경우 Fig. 5(b)에 나타내었다. 입력벡터 유형별, 은닉층 수별, 고장 상태별 진단 정확률은 Table 1과 같다.

실험결과 LP계수와 2개의 은닉층을 사용할 때, 이 5가지 유형의 고장진단을 위한 학습 수렴속도와 진단 성능이 최적임을 보였다. 실험 결과는 Fig. 5(a), (b)와 같이 은닉층의 개수가 각각 5개, 6개일 때 진단의 정확률이 오히려 낮아지는 경우도 있으며 학습의 수렴 속도도 학습 횟수 2000번 정도로 은닉층의 개수가 2개일 때 학습 수렴 속도가 학습 횟수 11번 정도에 비해 스펙트럼의 경우 0.42% 떨어졌고, LP계수의 경우 5.38% 떨어짐을 확인하였다.

학습 시간 평가 실험은 Windows 10, i5-6200 CPU, 클럭 주파수는 2.3 GHz, 주메모리는 8 GB인 PC 환경에서 실행하였으며 C 프로그램 함수인 clock함수를 사용하여 프로그램 실행시간을 측정하였다. 측정 결과 입력벡터가 스펙트럼이고 2개의 은닉층을 사용할 때 학습 소요시간은 16분 14초, 6개의 은닉층을 사용할 경우는 22분 26초로 측정되었다. 입력벡터가 LP

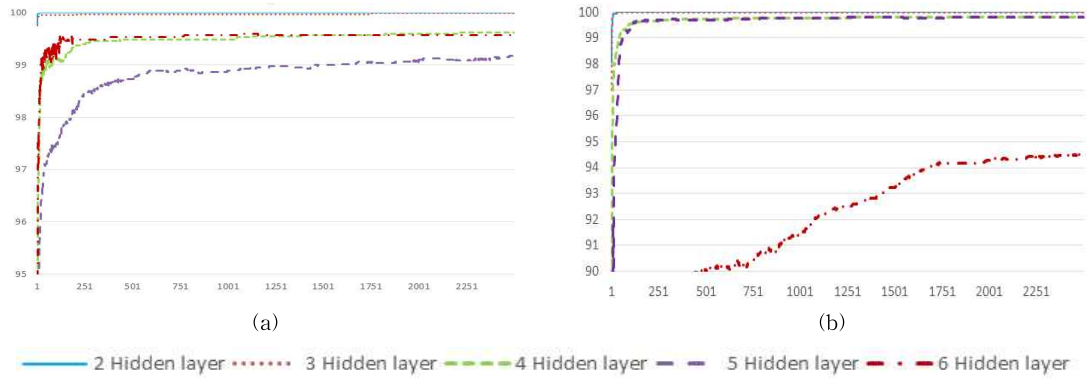


Fig. 5. Diagnosis accuracy according to the number of hidden layers (a) FFT, (b) LPC.

Table 1. Diagnosis accuracy according to the number of hidden layers (%)

number of hidden layers State	Spectrum input					LPC input				
	2	3	4	5	6	2	3	4	5	6
Normal	100	100	99.89	98.22	99.89	100	100	99.56	99.67	98.33
Unbalance	100	100	100	100	100	100	100	99.89	100	100
Faulty Bearing	100	100	99.44	98.89	99.56	100	100	99.89	99.67	90
Misalignment	100	100	99	98.78	98.67	100	100	99.78	99.89	85.78
Looseness	100	100	99.78	100	99.78	100	100	99.89	99.78	99
Average	100	100	99.62	99.17	99.58	100	100	99.80	99.80	94.62

계수일 때, 은닉층이 2개, 6개 각각의 소요시간은 2분 19초와 7분 21초로 측정되어 시간이 1/8배 정도 단축됨을 확인하였다.

### 3.2 학습률 변화에 따른 진단 정확률

학습률  $\alpha$  값이 0.01, 0.001, 0.0001, 0.00001 일 때 신경망을 2500번 반복 학습한 후, 각 학습률에 대한 진단 정확률을 측정하였다. Table 2와 같이 학습률의 변화에 따른 진단 정확률은  $\alpha$  값이 0.01일 때 100%이고,  $\alpha$  값이 0.00001일 때 99.2%로써 큰 차이가 없음

을 알 수 있었다. 학습률 4가지 값에 따른 진단 정확률은 100%에 가까운 결과를 얻었고 그 차이는 미미함을 알 수 있었다.

### 3.3 유도전동기의 회전속도별 진단 정확률

유도전동기 회전속도 별 고장진단 성능을 평가하기 위해서 회전속도 1000 RPM, 1200 RPM, 1500 RPM 별로 수집한 진동데이터를 사용하여 독립된 신경망을 각각 학습시킨 뒤 고장 진단 정확률을 측정하였다. 스펙트럼 입력벡터를 사용하였을 때의 결과는

Table 2. Diagnosis accuracy by type of failure according to Alpha (%)

State \ Alpha	0.01	0.001	0.0001	0.00001
Normal	100	100	100	99.56
Unbalance	100	99.89	100	100
Faulty Bearing	100	100	100	99.11
Misalignment	100	100	100	97.56
Looseness	100	100	100	100
Average	100	99.98	100	99.25

Table. 3. Diagnosis accuracy by RPM and fault type learned by integrating RPM

(%)

State	RPM	Spectrum			LPC		
		1000	1200	1500	1000	1200	1500
Normal		96.56	99.2	100	95.44	92.78	99.56
Unbalance		99.78	100	99.44	91.44	98.44	99.89
Faulty Bearing		100	100	100	99.78	100	100
Misalignment		99.67	99.11	99.89	99.67	95.00	99.78
Looseness		99.67	100	99.78	99.78	100	99.67
Average		99.14	99.66	99.82	97.22	97.24	99.78
Global Average		99.54			98.08		




Fig. 6. Diagnosis accuracy according to the induction motor RPM (a) spectrum (b) LPC.

Fig. 6(a), LPC 벡터를 사용한 결과는 Fig. 6(b)와 같다. 1000 RPM에서는 정상상태와 베어링 결함 상태에서 96% 정도의 진단 정확률이 측정되었다. 1200 RPM에서의 진단 정확률은 정상상태와 축 정렬 불량 상태에서 92%, 베어링 결함 상태에서 96%이다. 1500 RPM의 경우 모든 유형에서 100% 정확률이 측정되었으며 회전속도가 진단 정확률에 영향을 미치는 것을 알 수 있었다.

### 3.5 회전속도 통합데이터로 학습한 경우의 진단 정확률

유도전동기의 회전속도를 구분하지 않고 1000 RPM, 1200RPM, 1500RPM 별로 수집한 진동데이터 전체를 통합하여 학습시킨 후 고장 유형별 진단 정확률을 측정된 결과는 Table 3과 같다. 실험 결과 스펙트럼의 경우 전체 정답률은 99.54%이고 LPC의 경우 전체 정답률은 98.08%로 모두 98% 이상의 높은 정답률을 보였고 두 경우의 차이는 1% 내외로 유사한 진단 정확률을 보였다.

## 4. 결 론

본 연구에서는 유도전동기의 고장을 진단하기 위해서 LPC계수를 이용하여 DNN을 통과 시킨 후 유도전동기의 고장 검출 및 진단 방법을 제시하였다. 유도전동기 고장진단용 시뮬레이터와 가속도센서를 사용하여 정상 상태, 베어링 결함 상태, 기계적 느슨함 상태, 불균형 상태, 축 정렬 불량 상태를 만들고서 회전수는 RPM 1000, 1200, 1500별로 각 상태별 진동데이터를 표본화 주파수 1 kHz, 16bit로 양자화 하였다. 상기 5가지 상태와 3가지 RPM 별로 각각 10분씩 모두 150분 분량의 진동데이터를 수집하여 전체 진동데이터에서 60%를 학습용으로, 나머지 40%를 성능 평가용으로 사용하였다. 실험 결과 본 논문에서 제안한 LPC와 DNN을 결합한 유도전동기 고장진단 방법이 기존 스펙트럼과 신경망 학습을 이용한 방법보다 실행 시간이 1/8 정도로 단축되면서 기존 방식과 유사한 98% 이상의 고장진단 성공률을 보임으로써 제안된 방법이 효율적임을 보였다.

## REFERENCE

- [1] S.M. Lee, *Fault Diagnosis for Rotating Machinery with Clearance Using HHT*, Master's Thesis of Univ. of Sungkyunkwan, 2007.
- [2] D.V. Tuan, *Fault Detection and Diagnosis for Induction Motors using Local Feature, Variance, Cross-correlation and Wavelet*, Ph. D. Dissertation of University of Ulsan, 2009.
- [3] H.S. Han, "Feature Vector Decision Method of Various Fault Signals for Neural-Network-Based Fault Diagnosis System," *Journal of the Korean Society for Noise and Vibration Engineering*, Vol. 20, No. 11, pp. 1009-1017, 2010.
- [4] I.A. Basheer and M. Hajmeer, "Artificial Neural Network: Fundamentals, Computing Design, and Application," *Journal of Microbiological Methods*, Vol. 43, pp. 3-31, 2000.
- [5] 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, 1995.
- [6] S. Thanagasundram and F.S. Schlindwein, "Autoregressive Based Diagnostics Scheme for Detection of Bearing Faults," *Proceedings of ISMA2006 Noise and Vibration Engineering Conference*, pp. 3531-3546, 2006.
- [7] 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, pp. 515-533, 2004.
- [8] Q. Sun, Y. Tang, W.Y. Lu, and Y. Ji, "Feature Extraction with Discrete Wavelet Transform for Drill Wear Monitoring," *Journal of Vibration and Control*, Vol. 11, No. 11, pp. 1375-1390, 2005.
- [9] M. Ge, G.C. Zhang, and Y. Yu., "Feature Extraction From Energy Distribution of Stamping Processes Using Wavelet Transform," *Journal of Vibration and Control*, Vol. 8, pp. 1323-1332, 2002.
- [10] 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.
- [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.
- [12] C.H. Lee, "Development of the Fault Diagnostic System on th Rotating Machinery Using Vibration Signal," *Journal of the Korean Society of Precision Engineering*, Vol. 21, No. 12, pp. 75-76, 2004.
- [13] S.S. Lee, *Fault Diagnosis System of The Rotating Machines in Power Plant Using LPC*, Master's Thesis of University of Ulsan, 2004.
- [14] Y. Bengio, A. Courville, and P. Vincent, "Representation Learning: A Review and New Perspectives," *IEEE Transactions on Pattern Analysis and Machine Intelligence, Special Issue Learning Deep Architectures*, pp. 1798-1828, 2013.
- [15] G. Hinton, L. Deng, D. Yu, G. Dahl, A. Mohamed, and N. Jaitly, et al., "Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups," *IEEE Signal Processing Magazine*, Vol. 29, Issue 6, pp. 82-97, 2012.





류진원

2011년~현재 울산대학교 IT융  
합학부 학사과정  
관심분야: Signal Processing,  
Drone System, Fault  
Detection



정의필

1978년 울산대학교 전기공학과  
공학사  
1980년 고려대학교 전기공학과  
석사  
1985년 오레곤주립대학교 전기  
및 컴퓨터공학과 석사

1997년 뉴욕대학교 전기공학과 박사  
현재 울산대학교 IT융합학부 연구교수  
관심분야: Signal Processing, Drone System, Fault  
Detection



박민수

2012년~현재 울산대학교 IT융  
합학부 학사과정  
관심분야: Signal Processing,  
Fault Detection



이정철

1984년 서울대학교 전자공학과  
공학사  
1988년 서울대학교 전자공학과  
공학석사  
1998년 서울대학교 전자공학과  
공학박사

현재 울산대학교 IT융합학부 부교수  
관심분야: 디지털신호처리, 음성신호처리, 음성합성



김남규

2012년~현재 울산대학교 IT융  
합학부 학사과정  
관심분야: Signal Processing,  
Drone System, Fault  
Detection