

웨이블릿 분석과 신경망을 이용한 농형 유도전동기 고장 진단

The Diagnosis of Squirrel-cage Induction Motor Using Wavelet Analysis and Neural Network

이재용 · 강대성*
Jae-Yong Lee · Dae-Seong Kang*

요약

산업 전반에 걸쳐 유도 전동기는 필수적인 요소로 그 비중이 매우 크다. 이에 수반하여 유도 전동기의 고장은 단지 유도 전동기라는 전기기에 국한되는 것뿐만 아니라 전동기의 다른 부분에 영향을 미치거나 다른 고장을 유발하는 원인이 되기도 한다. 이는 산업 시스템의 신뢰성을 실추시키는 악영향을 수반한다. 따라서 이를 예방하기 위한 여러 연구가 진행되고 있다. 본 논문에서는 산업 전반에 걸쳐 널리 사용되고 있는 유도 전동기의 고장을 자동 판별하는 시스템을 제안한다. 이 시스템의 고장 진단 방법은 고정자 전류를 취득하여 이를 웨이블릿 분석하여 그 신호의 특징을 추출한다. 이렇게 추출된 신호의 특징을 신경망을 사용해서 자동 판별하게 된다. 유도 전동기의 고장의 대부분을 차지하는 3가지의 고장을 모의 고장 유도전동기를 사용해서 시험하였다. 제안하는 시스템은 3가지의 유도 전동기의 고장을 간단한 장비로 진단을 수행하여 신뢰도 높은 고장 진단 시스템을 제안하였다.

Abstract

The induction motor is given a great deal of weight on the industry generally. Therefore, the fault of the induction motor may cause the fault to effect another parts or another faults in the whole system as well as in itself. These are accompany with a lose of the reliability in the industrial system. Accordingly to prevent these situation, the scholars have studies the fault diagnosis of the induction motor.

In this paper, we proposed the diagnosis system of the induction motor. The method of diagnosis in proposed system is extracted the feature of the current signal by the wavelet transform. These extracted feature is used the automatic discrimination system by the neural network. We experiment the automatic discrimination system using the three faults imitation that often generated in the induction motor. The proposed system have achieved high reliable result with a simple devices about the three faults.

Keywords : Induction motor, wavelet analysis, neural network, fault diagnosis

1. 서론

전기적 에너지를 기계적인 힘으로 바꾸는 대표적 기기인 유도 전동기는 철도, 항만 등 산업 여러 분야에서 그 사용과 역할이 크다. 또한 유도 전동기는 산업 시스템에서 중추적인

역할을 하기 때문에 유도 전동기의 유지 및 관리 역시 그 중요성이 크다 하겠다. 유도전동기는 생산 현장에서 주된 동력 원으로 자리 잡고 있으며, 구조적인 강점 때문에 산업 전반에 널리 사용되고 있다. 오랜 사용과 운전 조건에 따라 각 요소별로 고장이 발생할 수 있으며, 이를 적시에 발견하지 못하고 방치하는 경우 유도전동기뿐만 아니라 전력 계통 시스템에도 악영향을 야기할 수 있다. 이는 시스템의 전체적인 신뢰도를 떨어뜨리고, 복구를 위한 추가 인력, 재정 및 시간의 손실을 초래한다. 따라서 유도전동기의 조기 고장 검출과 고장 분류는 매우 중요한 문제라 할 수 있다. 이에 따라 공정의 생산성 및 안정성의 향상을 위해 시스템 고장의 검출 및 분류에 관한 연구가 활

* 동아대학교 전자공학과

논문 번호 : 2007-4-5 접수 일자 : 2007. 8. 20

심사 완료 : 2008. 1. 19

* 이 논문은 한국전력공사(전력기반조성사업센터)에서 지원한 전력변화 시스템 신기술 연구센터(과제번호 2006-0273)의 사업으로 수행되었습니다.

발히 진행되고 있다[1]. 유도 전동기의 고장은 주로 베어링 및 회전자, 고정자에서 발생하며 고장 검출 방법으로는 이 세 부분의 구성 요소의 고장을 검출하며, 특히 진동 방법을 이용한 감시방법이 주류를 이루고 있다. 그러나 이 진동 신호를 이용하는 고장 방법은 진동 데이터를 얻기 위하여 부피가 큰 진동 센서를 필요로 하며 비용이 비싸고 고장 진단을 위하여 고장 원인별 필요한 데이터를 얻기 위하여 필요한 부위에 진동 센서를 부착하여야 하는 단점을 가지고 있으며 모든 전동기에 진동 센서를 기구적으로 부착한다는 것이 불편할 뿐만 아니라 경제적인 면에서도 권장할만하다고 볼 수 없다. 또한 유도 전동기의 고장은 오랜 시간에 걸쳐서 진행되는 경우가 많으므로 적절한 시기에 고장을 진단하지 않는다면 전동기 뿐 아니라 전체 시스템에 악영향을 미칠 가능성이 있으므로 조기 고장 진단이 필요하다.

본 논문에서는 유도 전동기의 결함을 웨이블릿 변환 기반 스펙트럼 분석 방법을 이용하여 특징을 추출한다. 일반적으로 유도 전동기 대부분의 전기적인 문제는 진동 또는 전류 신호 스펙트럼 분석에서 전원 주파수의 2배 성분에서 정상상태보다 높은 진동 진폭이 발생하며, 기계적인 문제는 운전 주파수 성분이 탁월하다[2]. 스펙트럼 분석으로 특징을 추출한 뒤 각 고장 특징의 최적 분류를 위해 신경망을 이용해 최종적인 유도 전동기 고장진단을 수행한다.

II. 신호 분석 기술

Wavelet 변환은 1970년대 프랑스의 지질학자인 Morlet에 의해 처음 제안 되었으며 현재 다양한 분야에서 활발하게 발전, 적용되고 있는 근세기 들어 가장 주목 받고 있는 이론이다. Wavelet 변환은 Fourier 변환 및 창 함수를 이용한 Fourier 변환 같은 시간-주파수 변환과는 달리 신호에 포함되어 있는 스케일에 대한 뛰어난 분해능을 지니고 있으며, 이에 따라 시간-스케일 변환이라고도 한다.

여기서 말하는 스케일(scale)은 주파수의 역으로서 수학적 연산으로 scaling은 신호를 팽창 시키는 것이나 축소시키는 것, 즉 큰 스케일 신호는 팽창에 작은 스케일 신호의 압축에 대응한다. 주어진 함수에서 웨이블릿은 $s > 1$ 이면 신호를 팽창시키고, $s < 1$ 이면 신호를 압축한다.

분석된 신호 $x(t)$ 에 대해 mother wavelet은 처리 과정에서 모든 창들에 대한 원형으로 작동되도록 선택되어진다. 선택된 모든 창들은 팽창(또는 압축)되고 mother wavelet에서 쉬프트된 버전이 된다. 분석은 고주파수로부터 저주파수 쪽으로 진행된다. s 의 첫 번째 값은 가장 압축된 웨이블릿에 대응하게 될 것이다. s 의 값이 증가함에 따라 웨이블릿은 팽창하게 된다.

수학적인 관점에서 보자면 Fourier에 의해 정의된 Fourier transform은 기저 함수를 사용하여 분석하고 함수를 재건축한다. 몇몇 고정된 상수들에 의한 벡터들을 곱한 후에, 그 결과들의 합을 취함으로써 벡터 공간에 있는 모든 벡터는 벡터 공간에 있는 기저 벡터들의 선형 결합으로 나타낼 수 있다. 신호의 분석은 상수들(변환 계수 또는 Fourier 계수, 웨이블릿 계수 등)

을 추정하는 것이다. 벡터 공간의 기저(basis)는 선형적으로 독립 벡터들의 집합이다. V 에서 벡터 v 는 이런 기저 벡터들의 선형 결합으로 쓰여 질 수 있다. 하나의 벡터 공간에 대해서 한개 이상의 기저가 있을 것이다. 이 숫자는 벡터 공간의 차원(dimension)으로 알려진다. 2차원 공간의 기저는 2개의 벡터가 될 것이다.

$$v = \sum_k v^k b_k \quad (1)$$

기저 함수 $\psi_k(t)$ 들을 가진 기저 벡터들 b_k 와, 함수 $f(t)$ 를 가진 벡터 v 를 대체함으로써 쉽게 함수로 일반화 될 수 있다.

$$f(t) = \sum_k \mu_k \phi_k(t) \quad (2)$$

복소지수 함수들은 FT에 대해서 기저함수가 있다.

$L^2[a, b]$ 에서 $-L^2[a, b]$ 는 간격 $[a, b]$ 사이에서 자승의 적분 함수들의 집합 함수 $f(t), g(t)$ 가 있다고 할 때, 두 개의 함수들의 내적은

$$\langle f(t), g(t) \rangle = \int_a^b f(t)g^*(t)dt \quad (3)$$

위 내적의 정의에 따르면 CWT(Continuous Wavelet Transform)는 $\psi_{(\tau,s)}(t)$ 의 기저 함수가 될 수 있다.

$$\psi_{\tau,s} = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (4)$$

CWT의 이 정의는 웨이블릿 분석이 기저함수(wavelet)과 신호 자체의 유사성을 측정한다. 계산된 CWT 계수들은 신호와 현재 스케일에서 웨이블릿과 얼마나 가까운지를 말한다[3].

III. 자동 진단 알고리즘

1. 신경망의 모델링

생물학적인 신경세포는 수상돌기(dendrite), 축색돌기(axon) 그리고 세포체(cell body or soma)로 이루어져 있는데, 수상돌기는 인접 뉴런으로부터 신경 흥분이 세포체로 입력되는 통로이며 축색돌기는 가늘고 긴 신경섬유로 신경 흥분을 전달하는 역할을 한다. 세포체는 일정 시간동안 입력된 자극을 세포체 내에서 가중되고 그 값이 임계치 이상이면 뉴런이 활성화하여 축색돌기로 자극이 전달되는 메커니즘을 갖는다.

이런 생물학적인 신경세포에서 수상돌기는 입력 유닛으로 설정하고, 세포체의 가중합은 각 유닛과 연결된 연결 가중치의 곱의 합으로 계산되고, 이것이 활성화함수라고 하는 함수에 의하여 출력 값을 얻도록 모델링 될 수 있다.

이것을 좀 구체적으로 살펴보면, 각 유닛과 가중치는 모두 변수화하여 설정한다. 즉 입력 값은 수치적으로 설정될 것이고

이를 변수에 저장하는 과정이 입력을 받는 과정이 된다. 그리고 두 뉴런 간에 연결의 세기를 의미하는 가중치도 2차원 배열로 처리하면 입출력에 대한 각각의 연결 가중치를 설정할 수 있다. 세포체의 기능인 가중함도 연산자를 통하여 구현될 수 있다. 여기서 활성화 함수는 그림 1과 같은 함수들을 사용한다.




그림 1. 활성화 함수
Fig. 1. Activation functions

가장 간단한 활성화 함수로 (a)와 같은 계단함수가 있다. 입력이 임계값 이상이 될 때만 출력이 1로 활성화 되는 함수이다. 다음으로 많이 사용하는 활성화 함수가 (b)와 같은 시그모이드 함수로 식(5)와 같이 표현한다[4].

$$\frac{1}{1 + e^{-x}} \quad (5)$$

2. Back Propagation

역전파(back propagation) 학습 알고리즘은 전향 단계와 후향 단계로 이루어진다. 학습에서 중요한 것은 연결 강도의 갱신인데 역전파 알고리즘은 후향 단계에서 연결 강도의 갱신이 이루어진다. 전향단계는 신경 회로망에 입력 패턴을 제시하고, 각 노드에 대해서 입력 함수화 활성화 함수를 이용하여 출력을 산출하는 단계이다. 이 때 입력되는 신호는 전방향 즉, 출력층 방향으로만 전달된다. 초기에 임의로 정한 연결강도에 의하여 출력층에서 출력 값은 목표 값과 당연히 일치하지 않고 큰 오차를 발생하게 될 것이다. 후향 단계는 목표 출력과 실제 출력 차이를 계산하여 오차를 구하고, 이를 역방향 즉, 출력층에서 입력층으로 순서대로 층과 층 사이의 연결강도를 갱신하는 단계이다. 연결강도를 조절한 후, 다시 입력을 넣어 계산하면 출력은 처음 시도 때보다 오차가 작은 값을 얻게 된다. 이를 반복하여 시스템이 안정될 때까지 즉, 총 오차의 합이 정해진 오차의 기준치에 도달할 때까지 실행시켜서 원하는 값에 수렴시키는 것이다. 그림 2는 이 과정을 나타내고 있다.

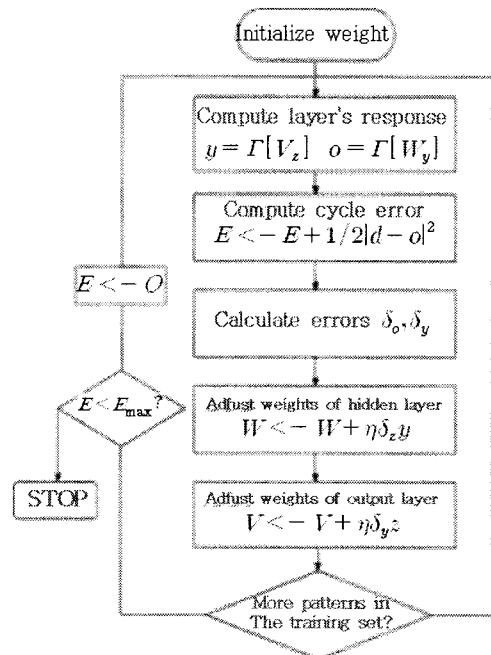


그림 2. 역전파 학습 알고리즘
Fig. 2. The algorithm of backpropagation learning

IV. 유도전동기의 고장

유도 전동기의 고장은 기계적인 고장과 전기적인 고장으로 크게 나눌 수 있으며, 고장의 원인으로는 대개 베어링, 고정자, 회전자에 결함으로 간추릴 수 있다.

전동기의 베어링은 회전 기계의 하중을 지지하는 가장 중요한 부분이다. 윤활급유에 의해 그 기능이 유지되며 원활하고 안정하게 하중을 지지하여 전동기의 운전을 가능케한다. 전동기의 베어링에는 구름 베어링과 미끄럼 베어링의 두 종류가 있다. 일반적으로 중소 용량의 전동기에는 구름 베어링이 많이 사용되고 대용량 전동기에는 미끄럼 베어링이 사용된다. 구름 베어링은 전동체의 형에 따라 볼 베어링과 롤러 베어링으로 대별된다. 볼 베어링은 비교적 큰 하중에 잘 견디기 때문에 범용 전동기에 가장 많이 사용된다. 그리고 롤러 베어링은 볼 베어링 보다 고 하중에 더 잘 견디는 특징이 있다. 구름 베어링은 윤활이 부적당하거나 불완전한 밀봉으로 인해 먼지나 습기가 노출되거나하면 이것이 베어링 고장의 원인이 된다. 정상적인 상태에서 운전을 계속해도 일정 기간이 경과하면 윤활리스의 열화, 마모에 의한 정밀도 저하, 구름면의 박리, 이상음의 발생, 전동의 증가 등에 의해 더 이상 견딜 수 없게 된다. 이것은 구름 베어링이 어떤 하중을 받아 베어링의 내외주의 궤도면이나 전동면이 끊임없이 반복 응력을 받게 되어 재료의 피로 파손이 생기기 때문이다.

베어링 고장은 부적당하거나 불충분한 윤활, 반경, 그리고 샤프트 편향, 부적절한 마운팅, 정렬로 인한 축 스트레스에 의해 발생할 수 있다. 발생하는 고장 주파수는 베어링의 기계적 구조와 전동기의 회전속도에 의해 결정된다. 고장시 발생하는 특성 주파수는 다음과 같다[4].

$$\begin{aligned}
 f_o &= f_s \pm (0.6nfr) \\
 f_i &= f_s \pm (0.4nfr)
 \end{aligned}
 \tag{6}$$

여기서 f_s 는 공급전원의 주파수, k는 양의 정수, n은 베어링 볼의 수, f_r 은 전동기의 회전속도이다.

고정자 고장은 절연체 고장의 원인인 inter-turn 권선 고장 때문에 발생할 것이다. 이 고장은 고조파 공극 자속과 전류-시간 고조파 변화에 의해 동반된 고정자의 불균형을 이끈다. 공급 전류의 상대적인 변화를 측정하는 방법으로 고장을 발견한다[5].

전동기의 회전수를 0에서 N(rpm)까지 가속하여, 시동 완료 후 회전자가 보유하는 운동 에너지는 시동 완료까지의 회전자의 전손실과 같다. 이와 같이 시동 역상 제동 역전에 있어서의 회전자의 전손실은 회전자가 갖고 있는 운동 에너지와 관계가 있다. 유도 전동기를 무부하로 운전하는 경우 회전자의 전손실은 역상 제동 1회는 시동의 3회, 역전 1회는 시동의 4회에 상당하게 된다. 따라서 고빈도의 시동 정지, 역상 제동, 역전은 그 회수에 비례하여 회전자에 손실이 생기게 되며, 이들 손실의 축적에서 회전자의 과열을 초래하게 된다.

회전자 고장은 파동 부하나 직접적 온라인 시동의 결과인 바와 엔드 링 사이 결합의 문제이다. 결과는 전류가 보다 많은 파손의 위험의 증가와 함께 남아있는 바에서 증가한다는 것이다. 회전자 고장은 공급 전류와 축의 펄드에서의 토크 파동, 속도 불안정, 진동, 주파수 요소의 변화를 일으킨다. 회전자 권선 손상에 의해 발생하는 주파수 성분은 다음과 같다[6][7][8].

$$f_{brb} = f_s \left[k \left(\frac{1-s}{p/s} \right) \pm s \right]
 \tag{7}$$

여기서 f_s 는 전원주파수, $\frac{2k}{p} = 1.5, 7, 13, \dots$ 이다

V. 고장진단 방법

제안하는 고장진단 방법을 실험하기 위해서 그림 3과 같은 방법으로 물리적 연결 및 신호를 처리한다.

고정자에서 전류신호를 취득하기 위해서 적절한 신호 컨디셔닝을 수행한다. 여기서 신호 컨디셔닝은 기본적인 신호의 증폭, 필터링 및 절연의 기능을 수행하게 된다. 원하는 신호를 수집하기 위해서 데이터 수집 장치를 연결한 뒤에 PC 기반으로 데이터 처리를 하기 위해서 USB 인터페이스를 이용해서 PC에 연결한다. 이렇게 취득한 신호를 웨이블릿 분석을 통해 특징을 추출하고 신경망을 이용해서 그 신호의 자동 분류를 하게 되어서 최종적으로 자동 고장 진단을 수행하게 된다.

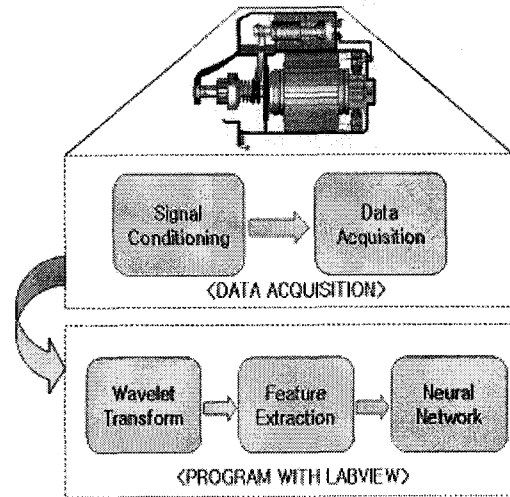


그림 3. 유도전동기 고장진단 방법
Fig. 3. A method of fault diagnosis for induction motor

VI. 실험 및 결과

본 논문에서 제안하는 방법으로 실험을 하기 위해서 먼저 모의 고장 유도전동기를 제작하였다. 각각의 모의 고장 유도전동기는 유도 전동기 고장의 빈도가 가장 높은 베어링 마모 및 회전자 바 손실, 고정자의 고장을 대상으로 실험하였다.

다음의 표 1은 유도전동기의 제원을 나타내고 있다.

표 1. 유도전동기의 제원
Table 1. The characteristic of induction motor

구분	항목	치수
사양	정격 출력 [kW]	7.5
	정격 전압 [V]	220/280
	정격 속도 [rpm]	1760
	정격 토크 [Nm]	40
고정자	슬롯 수	36
	외 경 [mm]	220
	내 경 [mm]	150
회전자	극 수	4
	공 극 [mm]	0.5
	외 경 [mm]	149
	적층길이 [mm]	110
	회전자 바	A1

그림 4는 실험 장치를 나타내고 있으며, 표 1의 유도전동기와 DAQ 장치 그리고 노트북이 사용되었다.




그림 4. 고장진단 시연

Fig. 4. The operation test of fault diagnosis

유도전동기의 고장을 진단하기 위한 프로그램 개발 도구로서 National Instrument의 LabVIEW를 사용하였다. LabVIEW는 데이터의 수집, 분석 및 표현의 세 부분으로 구성되어 있으며, 하드웨어로 연결하여 사용자와의 인터페이스에 최적화 되어 있다. 이는 프로그램 상에서의 인터페이스에 대한 설정만으로도 데이터 측정이 가능하다는 것을 말하며, VI(Virtual Instrument)를 이용해서 다양한 기능의 함수를 이용한 분석 및 저장, 모니터링을 PC에서 쉽게 구현할 수 있다. LabVIEW는 그래픽 언어 기반으로 텍스트 언어의 workspace에 해당하는 블록 다이어그램과 최종 실행창인 프론트 패널로 구성되어 있다.

물리적 연결로부터 PC에서 신호를 처리하기 위해서 LabVIEW에서 DAQ 어시스턴트를 이용해서 PC에서 신호를 처리한다. 그림 5는 DAQ 어시스턴트 실행화면을 보이고 있다.

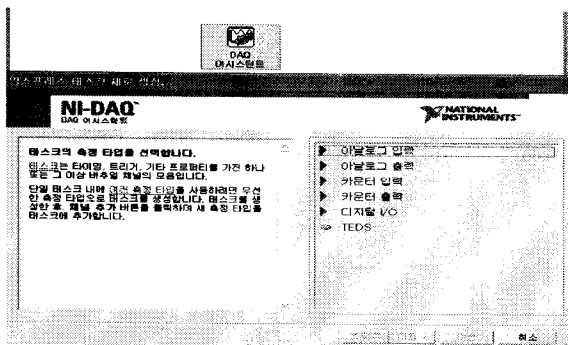


그림 5. DAQ 어시스턴트

Fig. 5. DAQ assistance

유도 전동기의 고장 진단 시스템 구성을 위해 고정자 전류를 취득하고 이 전류 신호를 데이터 수집 장치를 거쳐 USB 버스를 통해서 받아들인다. 받아들인 신호를 웨이블릿 변환하고 웨이블릿 계수를 계산하여 신경망의 입력으로 사용한다.

DAQ로부터 입력된 신호를 웨이블릿 변환해서 계수를 계산하기 위해서 작성된 프로그램은 그림 6과 같다. 그림에서 CWT coef. 라고 표현된 부분에서 웨이블릿 계수를 계산하게되며, 이 계수들이 신경망의 입력이 된다.

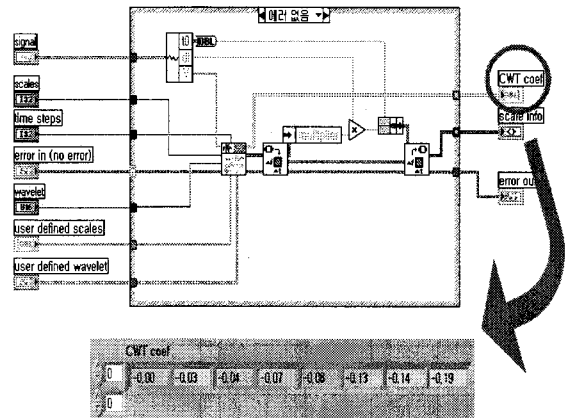


그림 6. 웨이블릿 변환 프로그램

Fig. 6. The program of wavelet-transform

고장을 진단하고 자동 인식을 하기 위해서 1초 마다 입력 신호의 웨이블릿 계수를 계산하고 10초 동안 10개의 웨이블릿 계수를 한 set으로 20개의 set을 테스트 패턴으로 신경망 입력으로 한다. 일반적으로 유도전동기의 고장은 갑자기 이루어지는 경우는 없고, 긴 시간에 걸쳐서 천천히 이루어지는 것이 대부분이므로 학습시간 및 진단시간에는 크게 구애받지 않는다. 신경망 뉴런의 개수는 그림 7과 같이 구성된다.


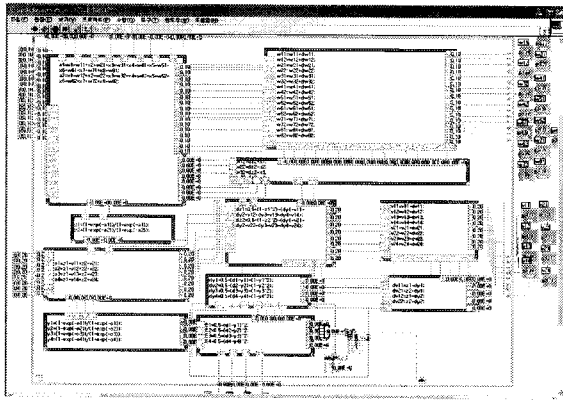


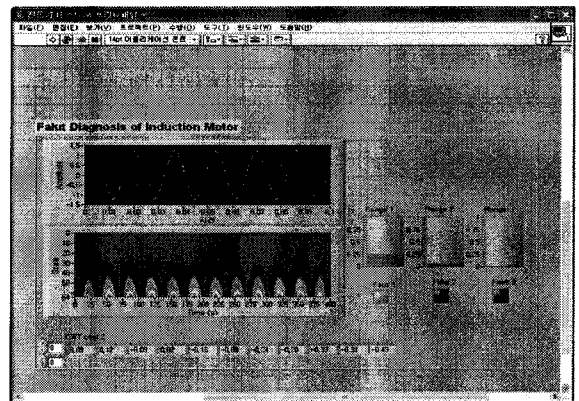
그림 7. 신경망의 구조

Fig. 7. The structure of neural network

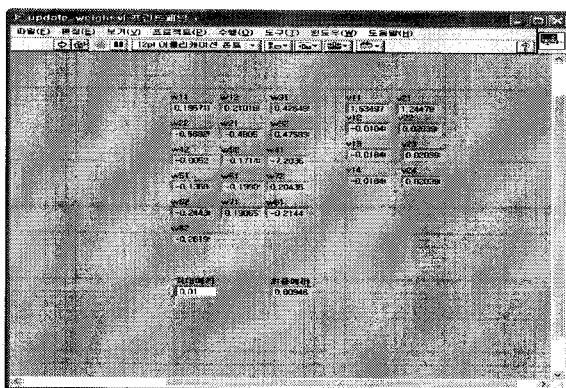
그림 6와 같이 모델링한 신경망을 LabVIEW를 통해서 학습한다. 각 고장 패턴별 학습을 마치고 학습된 가중치를 이용해서 자동 고장 진단을 하게 된다. 그림 8의 (a)는 신경망 부분의 블록 다이어그램을 보이며, (b)는 학습이 진행된 결과를 보이고 있다. 그림 7에서 input layer와 hidden layer 사이의 가중치 값이 그림 8(b)에서 w11부터 w82까지 계산된 결과를 보이고 있으며, 그림 7에서 hidden layer와 output layer 사이의 가중치 값에 해당되는 v11부터 v24까지 계산된 결과역시 결과에서 볼 수가 있다. 그림에서 최대에러를 0.01로 하였을 때 최대 에러보다 더 작은 값이 되었을 때 계산된 가중치 값이라는 것을 알 수가 있다.



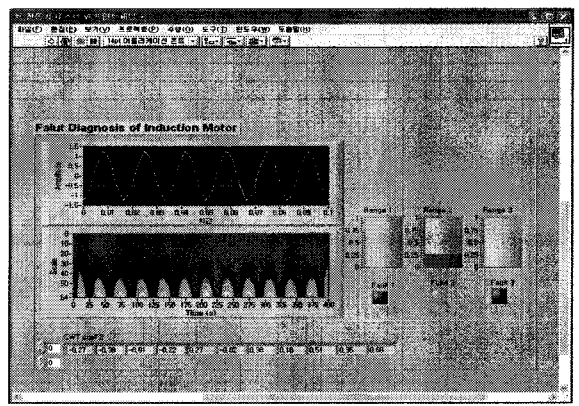
(a) 블록 다이어그램



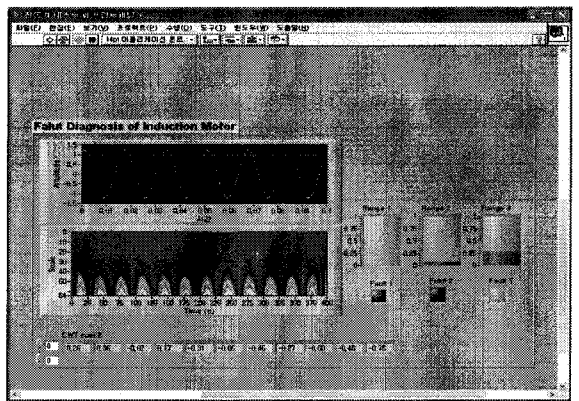
(b)



(b) 계산된 결과



(c)




(d)

그림 8. 신경망 학습

Fig. 8. The neural network learning

신경망 학습을 통해서 학습된 결과를 바탕으로 실제 유도전동기의 고장을 분류할 수 있었다. 그 결과 화면은 그림 9와 같다. (a)는 정상상태에서의 결과, (b)는 베어링 고장에서의 진단 결과, (c)는 회전자 이상에서의 진단결과, (d)는 고정자 고장에서의 진단결과이다.



(a)

그림 9. 유도전동기 고장 진단 화면

Fig. 9. The screen of fault diagnosis for induction motor

그림 9에서 위쪽 파형이 각각의 모드에 대한 raw 파형이며 다음 파형이 각각의 신호에 대한 wavelet 변환된 spectrogram이며, 아래의 숫자들은 각각의 시간에 대해서 계산된 wavelet 계수들을 나타내고 있다. 오른쪽의 랭크의 수위가 임의의 수치를 넘게 되면 고장으로 인식해서 아래의 불빛이 들어오게 되어서 고장임을 인식한다.

같은 장비로서 FFT와 신경망을 이용해서, 그리고 통계적 패턴인식 방법으로 주성분 분석 기법을 사용하여 유도 전동기의 고장 진단을 구현하였을 때의 진단율을 잡음을 고려하여 비교해 본 것이 표 2와 같다. 각각 100번의 시도를 연속적으로 시도

했을 때 그 결과를 나타내고 있다.

표 2. 고장진단 실험 결과

Table 2. The results of fault diagnosis experiments

고장 유형	FFT+신경망	PCA	제안 시스템
베어링 고장	82	78	92
회전자 바 단락	1 broke n	88	80
	2 broke n	89	85
고정자 고장	76	79	91

Ⅶ 결론

본 논문에서는 유도 전동기의 고장 진단 구현을 위하여 고정자 전류 신호를 취득하기 위하여 데이터 수집 장치를 이용하여 전류 신호를 취득한 뒤, 그 신호의 웨이블릿 계수를 취득하여 유도 전동기의 정상 상태 및 고장 유형을 분류하였다. 웨이블릿 계수를 신경망 알고리즘의 입력으로 이용하여, 자동 고장 판단을 하게 하였다.

본 논문에서 제안하는 유도 전동기 고장 진단 방법은 간단한 장치를 이용하여 효율적인 고장진단 프로그램을 구현하였다. 이 시스템은 간편한 장비를 이용해서 실시간으로 고장 진단 결과를 볼 수 있으므로 중소형 유도 전동기의 고장 진단을 위해서 유용하게 사용될 수 있을 것이라 사료된다. 이 후 여러 가지 환경에서 적용할 수 있는 상황을 고려하여 실제 상용화 될 수 있는 고장 진단 시스템을 만드는 것이 목표이며, 보다 다양한 고장의 유형의 진단을 위하여 진동 및 온도 등의 정보를 이용한 다면 보다 더 다양한 분야에서 신뢰성 높은 고장 진단 장치의 개발을 할 수 있을 것이라 기대된다.

참 고 문 헌

[1] Don-Ha Hwang, et al., A Method for Dynamic Simulation and Detection of Air-gap Eccentricity in Induction Motors by Measuring Flux Density, IEEE CEFC, pp.69, 2006,
 [2] 양보석, 진동신호분석기술을 이용한 유도전동기의 결합분석 및 진단, 인터비전, 2007
 [3] Robi Polikar, The wavelet tutorial-fundamental concepts & An overview of the wavelet theory, 2nd edition
 [4] 한학용, 패턴인식 개론, 한빛미디어, 2005
 [5] J. Penman, H. G. Sedding, and W. T. Fink, Detection and Location of Interturn Short Circuits in

The Stator Winding of Operation Motors, IEEE Trans. on Energy Conversion, vol. 9, No. 4, pp.652-658, December 1994

[6] R. R. Schoen, B. K. Lin, T. G. Habetler, J. H. Schlag, S. Farag, An Unsupervised On-Line System for Induction Motor Fault Detection Using Stator Current Monitoring, IEEE trans. Industry Application, vol. 31, No. 6, pp.1280-1286, 1995
 [7] 김부열, 우혁재, 송명현, 박중조, 김경민, 정희범, 인공신경망을 이용한 유도전동기 고장진단 한국해양정보통신학회논문지 제6권, 제2호, pp.294-299, 2002
 [8] 江畠春文, 전동기의 보수점검 및 고장진단, 성안당, 1994



이 재 용(Jae-Yong Lee)

2006년 동아대학교 전자공학(공학사)
 2008년 동아대학교 전자공학과(공학석사)

※주관심분야 : 영상처리, 패턴인식, RFID



강 대 성(Dae-Seong Kang)

1984년 경북대학교 전자공학과(공학사)
 1991년 Texas A&M 대학교 전자공학과(공학석사)
 1994년 Texas A&M 대학교 전자공학과(공학박사)

1995년~현재 동아대학교 전자공학과 교수.

※주관심분야 : 영상처리, 비디오 색인·검색, 영상압축