퍼지 및 지능시스템학회 논문지 2007, Vol. 17, No. 6, pp. 819-825

DFT와 웨이블렛을 이용한 유도전동기 고장진단

Fault Diagnosis of Induction Motors by DFT and Wavelet

권만준* · 이대종** · 박성무*** · 전명근*†

Mann-Jun Kwon*, Sung-Moo Park**, Dae-Jong Lee** and Myung-Geun Chun*†

* 충북대학교 전기전자컴퓨터공학부

* 충북대학교 BK21충북정보기술사업단

*** 한국폴리텍 IV대학 청주캠퍼스 전기과

요 약

본 논문에서는 DFT(Discrete Fourier Transform)과 웨이블렛을 이용한 고장진단 알고리즘을 제안한다. 제안된 방법은 주파수 기반의 DFT에 의한 고장패턴의 추출방법과 시간-주파수 기반의 웨이블렛을 이용한 고장패턴의 추출방법을 이용하여 특징점을 추출하였으며, 유도전동기의 최종진단은 DFT와 웨이블렛에 의해 추출된 특징값들을 효과적으로 융합할 수 있는 융합 알고리즘에 의해 수행한다. 개발된 알고리즘은 다양한 실측 데이터에 적용하여 그 타당성을 보였다.

키워드 : 고장진단, 유도전동기, DFT, 웨이블렛 변환

Abstract

In this paper, we propose a fault diagnosis algorithm of induction motors by DFT and wavelet. We extract a feature vector using a fault pattern extraction method by DFT in frequency domain and wavelet transform in time-frequency domain. And then we deal with a fusion algorithm for the feature vectors extracted from DFT and wavelet to classify the faults of induction motors. Finally, we provide an experimental results that the proposed algorithm can be successfully applied to classify the several fault signals acquired from induction motors.

Key Words : Fault diagnosis, Induction motor, DFT, Wavelet transform

1. 서 론

산업 현장에 널리 사용하고 있는 유도전동기들의 예기치 않은 고장은 전체 또는 일부 프로세스의 마비로 이어질 수 있으며, 이로부터 치명적인 사고와 경제손실을 초래할 수 있다. 최근, 이러한 고장들에 의한 사고를 미연에 방지할 수 있는 고장진단 기술이 유지보수의 측면과 더불어 중요한 부분으로 부각되고 있다. 일반적으로 유도전동기의 온라인 고장진단은 MCSA(Motor Current Signal Analysis)[1-4]에 의해서 이루어진다. 과거에는 진동 모니터링에 기반을 둔 연구가 많이 이루어져 있지만, 산업 전반에 사용되고 있는 중소형 유도전동기에 이러한 진단 시스템을 구성하는 것은 센서 및 진단 시스템의 성능사양을 높이기 위해 많은 비용을 지불해야 하며 또한, 센서의 위치에 따른 성능변화와 전동기 지지 환경에 따른 구조적 진동의 유입 문제를 무시하기가 어렵다. 반면에, MCSA 검출방법을 이용할 경우 절연상태를 제외한 고정자 및 회전자의 정적동적편심 및 베어링의 고장상태를 진단할 수 있다. 또한 온라인 상태에서도 고장진단을 수행할 수 있으므로, 최근 이들에 관한 연구가 활발히 진행되고 있다.

MCSA 검출방법에 의해 전류신호를 취득한 후 진단을 위해 사용되는 유도전동기의 고장상태를 효과적으로 표현할 수 있는 특징추출 기법이 요구된다. 특징벡터 추출기법에는 Park 변환에 의해 d-q 패턴을 추출하는 방법[3], 전류신호의 주파수스펙트럼(FFT)을 이용하여 특정 주파수를 추출하는 방법[4] 등이 주로 사용되어 왔다. 그러나 d-q 패턴의 경우 다양한 고장상태별로 고유의 패턴을 얻기가 어렵고, 노이즈가 존재하는 환경 하에서 고장패턴을 분류하는데 어려움이 있다. 또한 주파수 스펙트럼의 경우 부하변동 또는 입력전원의 고주파성분에 의해 주파수 성분이 변동되고, 고장상태별로 정확한 특정 주파수 스펙트럼을 추출하는데 한계점이 있다[5,6]. 이러한 문제점을 해결하기 위하여 시간축과 주파수 공간 내에서 해석이 가능한 웨이블렛을 이용하여 특징을 추출하는 방법이 제안되었다[7]. 이외에도 주성분분석기법(PCA:Principal Component Analysis)을 이용하여 특징을 추출하는 방법이 사용되고 있다[8].

본 논문에서는 기존의 분류 알고리즘들이 적용 분야에 따라 상호 보완적인 요소가 존재할 것이라는 가정하에서 DFT

+ : 교신저자

접수일자 : 2007년 10월 31일

완료일자 : 2007년 11월 21일

감사의 글 : 본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2007-2-046) 주관으로 수행된 과제임

(Discrete Fourier Transform)과 웨이블렛을 이용한 고장진단 알고리즘을 제안한다. 특징점 추출을 위해 주파수 기반의 DFT에 의한 고장패턴의 추출방법과 시간-주파수 기반의 웨이블렛을 이용한 고장패턴의 추출방법을 사용하였다. 유도전동기의 진단을 DFT와 웨이블렛에 의해 추출된 특징값들을 효과적으로 융합할 수 있는 융합 알고리즘에 의해 수행된다. 개발된 알고리즘은 다양한 실측 데이터에 적용하여 그 타당성을 보이고자 한다.

2. 제안된 유도전동기 진단 알고리즘

2.1 PCA에 의한 특징추출

PCA알고리즘은 데이터의 특징을 가장 잘 표현하는 공분산 행렬의 고유벡터를 구하여 고차원의 벡터를 줄여서 저차원의 벡터로 표현하는 기법으로 널리 사용되고 있다.

시계열의 전류신호는 공분산 행렬을 구하여 고유벡터를 구하고, 고유값 크기 순으로 나열하여 저차원의 특징벡터로 변환을 하여 처리하게 된다. 이에 대한 자세한 알고리즘을 알아보면 다음과 같다.

[단계 1] 측정된 p개의 학습용 전류신호를 1차원 열벡터로 변환한 후 식 (1)에 의해 전체 신호의 평균을 구한다.

$$m=\frac{1}{P}\sum_{i=1}^{P}x_i,\quad x_i\in R^{1\times n} \tag{1}$$

[단계 2] 학습용 전류신호에 대한 공분산행렬을 구한다.

$$\Omega=\overline{XX^T}$$
$$\overline{X}=[\bar{x}_1,\ \bar{x}_2,\cdots,\ \bar{x}_P],\ \bar{x}_i=x_i-m \tag{2}$$

[단계 3] 식 (2)에 의해 계산된 공분산에 대한 n개의 고유값과 n개의 고유벡터를 구한다.

$$\Omega v_i=\lambda_i v_i \tag{3}$$

[단계 4] 고유벡터 v_j를 고려하고자 하는 차원수(k) 만큼 고유값의 크기 순으로 재정렬한 고유벡터 $V\in R^{n\times k}$를 구한 후에 학습신호 x_i에 대한 특징벡터 $z_i\in R^{k\times 1}$를 식 (4)에 의해 산출한다. 식 (4)에서 알 수 있는 바와 같이 입력신호에 대한 특징벡터는 공분산에 대한 고유벡터를 이용하여 PCA 변환된 공간으로 투영함으로써 얻을 수 있다.

$$z_i=V^T(x_i-m)^T,\quad i=1,2,\cdots,P \tag{4}$$

[단계 5] PCA기법에 의해 i번째 검증용 입력전류 x'_i에 대한 특징벡터 z'_i를 산출한다.

$$z_i'=V^T(x'_i-m)^T \tag{5}$$

2.2 LDA에 의한 특징추출

유도전동기의 전류신호를 취득한 후 DFT에 의해 주파수 공간으로 변환한 후, 선형판별분석(LDA:Linear discriminant analysis)에 의해 차원이 축소된 고장패턴을 추출한다.

선형판별분석은 클래스내의 분산을 나타내는 WCS(within-class scatter)행렬 S_W와 클래스간 분산을 나타내는 BCS (between-class scatter) 행렬 S_B의 비율이 최대가 되는 행렬을 구하고, 이 행렬을 이용하여 선형변환하는 기법이다. 즉, 주성분분석기법과 같이 투영된 분산을 최대화하는 투영을 찾기보다는 클래스간의 차별성을 극대화시키는 최적의 투영행렬을 구한 후, 투영행렬을 이용하여 입력신호를 선형변환한다. 선형판별분석기법에 의한 특징추출 및 비교과정을 단계별로 살펴보면 다음과 같다.

[단계 1] 측정된 학습용 전류신호를 1차원 열벡터로 변환한 후 식 (6) 및 식 (7)에 의해 BCS 행렬인 S_B와 WCS 행렬인 S_W을 구한다.

$$S_B=\sum_{i=1}^{c}n_i(m_i-m)(m_i-m)^T \tag{6}$$

$$S_W=\sum_{i=1}^{c}\sum_{x\in C_i}(x-m_i)(x-m_i)^T \tag{7}$$

여기서, n_i는 i번째 클래스 C_i에서의 데이터 수이며, m_i는 i번째 클래스 C_i내의 평균값을 나타낸다. 또한, 식 (7)에서 m은 전체 클래스의 평균값이 된다.

[단계 2] 식 (8)과 같은 WCS행렬에 대한 BCS행렬의 비를 최대화하는 정규직교행렬을 갖는 최적의 사영행렬W를 식 (9)에 의해 구한다.

$$W=\arg\max_W\frac{|W^TS_BW|}{|W^TS_WW|}=[w_1,w_2,\cdots,w_m] \tag{8}$$

$$S_Bw_i=\lambda_iS_Ww_i,\quad i=1,2,\cdots,m \tag{9}$$

[단계 3] 학습신호 x_i에 대한 특징벡터 T_i를 구한다.

$$T_i=W^Tz_i=W^TV_i^T(x_i-m)^T \tag{10}$$

식 (10)에서 알 수 있는 바와 같이 선형판별분석을 하기 위해 우선 주성분분석기법에 의해 입력신호를 저차원으로 축소한 후, 산출된 특징벡터 z_i를 최적의 투영행렬 W에 의해 LDA공간으로 투영시킨다. 일반적으로 학습신호의 수(P)가 신호의 길이(N)보다 적을 경우 WCS행렬 S_W는 항상 비정칙이 된다. 이것은 사영행렬을 적당히 선택하지 않는다면 사영된 WCS행렬은 영이 될 수 있음을 의미한다. 따라서 이러한 문제점을 해결하기 위하여 주성분분석기법을 이용하여 입력신호를 저차원공간으로 축소한 후 선형판별분석을 수행한다.

2.3 DFT에 의한 특징추출

DFT는 시간영역의 디지털 신호를 처리하고 디지털 주파수 영역의 표현으로 변환하는데 적용될 수 있으며, 임의의 유한 수열에 대해 수치적으로 계산가능한 최종적인 퓨리에 변환으로 N개의 표본은 이산퓨리에변환계수라고 불리고, DFT 계수 $X(k)$ 역시 N-점 수열이다.

N점의 디지털 신호의 DFT를 정의하면 다음과 같다.

$$X(k)=\sum_{n=0}^{N-1}x(n)e^{-j2\pi n/N},\ 0\le n\le N-1 \tag{11}$$

역으로 이산신호 스펙트럼에서 이산수열을 얻으려면 다음과 같은 역 이산 퓨리에 변환으로 표현된다.

$$7x[n] = \frac{1}{N}\sum_{k=0}^{N-1} X(k)e^{j2\pi k/N}, 0 \le k \le N-1 \qquad (12)$$

식(11)를 이용하여 유도전동기의 전류신호를 주파수 공간으로 변환하여 특징 벡터를 추출한다.

2.4 웨이블렛에 의한 특징추출

웨이블렛 변환(Wavelet Transform)은 식 (13)에서 보는 바와 같이 비주기적인 신호분리가 가능한 Daubechies, Coiflet, Haar, Symmlet 등과 같은 기저함수라 부르는 원형(prototype) 웨이블렛 $\phi(t)$을 정의하고, 이 원형 웨이블렛을 시간축으로 b만큼 이동(translation)시키고, a만큼 스케일링(scaling)하여 다양한 웨이블렛을 구성하여 신호를 분해한다.

$$CWT_x(b,a) = \frac{1}{\sqrt{a}}\int x(t)\ \psi\ (\frac{t-b}{a})dt \qquad (13)$$

웨이블렛 변환에서는 주파수라는 용어 대신 스케일이라는 용어를 쓰며 하나의 웨이블렛을 통과한 신호를 하나의 스케일의 상세신호(detail signal)라 한다. 웨이블렛의 기저 함수들은 해상도가 다른 함수들의 집합으로 이루어져 있기 때문에 웨이블렛 변환은 다해상도 분해 특성을 가지고 있다. 즉, 높은 주파수 대역은 주파수 해상도가 낮고 낮은 주파수 대역은 주파수 해상도가 높은 다해상도 분해 특성을 나타내며 이러한 특성을 이용하면 다해상도 필터 뱅크들을 구현할 수 있다.

이산 웨이블렛 변환은 고역 통과 부분을 한 단계의 필터 뱅크로 구성하고, 저역 통과 부분을 계속적인 필터 뱅크로 확장하는 옥타브 밴드(octave-band) 구조와 고역 통과 부분도 필터뱅크로 확장하는 구조를 가지는 웨이블렛 패킷(wavelet packet)구조로 구현될 수 있다. 그림 1에서는 본 논문에서 사용된 옥타브 밴드 구조를 보이고 있는데, 여기서 $g[n]$은 저역 통과 필터를, $h[n]$은 고역 통과 필터를 각각 나타내며, 원형 웨이블렛으로부터 구성됨을 알 수 있다. 또한 $\downarrow 2$는 샘플의 개수를 1/2로 줄이는 데시메이션(decimation)을 나타낸다.

웨이블렛 변환을 이용한 유도전동기의 특징벡터는 취득된 한상의 전류신호를 웨이블렛 다해상도 기법을 이용하여 주파수 대역별로 분할한 후, 식 (14)에서 나타낸 바와 같이 대역별로 존재하는 계수의 합을 구하여 산출한다. 식 (7)에서 $W(j,k)$ 는 j번째 깊이(depth)와 k번째 노드(node)에서 웨이블렛 변환에 의해 얻어진 신호 $d_{jk} \in R^{1\times N}$를 이용하여 산출된 웨이블렛 특징값을 나타낸다.

$$W(j,k) \equiv \sqrt{\sum_{n=1}^{N}\frac{d_{jk}^2(n)}{N}} \qquad (14)$$

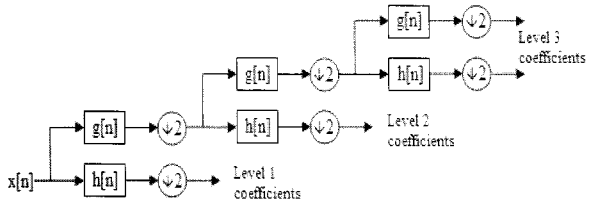

그림 1. 옥타브 밴드 구조
Fig. 1. Octave band structure

2.5 융합알고리즘에 의한 고장진단

그림 2에서는 DFT+LDA에 의해 산출된 특징벡터와 웨이블렛 변환에 의해 산출된 특징벡터의 융합에 의해 수행되는 구성도를 나타냈다. 그림 2에서 보는 바와 같이 진단하고자 하는 유도전동기에서 취득한 전류신호값을 각각 DFT+LDA와 웨이블렛에 의해 특징을 산출한 후, 미리 구축된 기준모델과의 거리비교를 통해 유사도를 산출한다. 각각 산출된 유사도값을 가중치합의 방법에 의해 최종적으로 고장분류 상태별 유사도를 산출하고, 기준모델과 유사도가 높은 모델을 선택하여 진단이 수행된다. 최종 융합 단계에서는 DFT+LDA와 DWT에 의한 추출된 특징 벡터의 공간 거리 데이터가 다른 범위에 있기 때문에 각각의 평균치를 구하여 가중치 기법에 의해서 같은 크기로 자동으로 설정하였다.

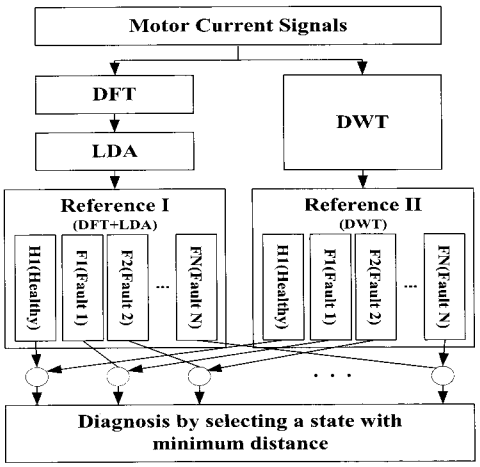

그림 2. 융합알고리즘에 의한 고장진단
Fig. 2. Fault diagnosis by a fusion algorithm

3. 실험 및 결과

3.1 실험장치 구성

유도전동기 고장진단을 위해 설치한 실험장치의 기본적으로 유도전동기 구동부분, 데이터 습득부분과 고장진단부분으로 구성되어 있다. 세부적으로 유도전동기 구동부분은 전동기구동부, 전동기, 안전장치, 다양한 전압표시장치, 전류센서와 진동센서의 구동회로, 그리고 전기적 브레이크 기능을 갖는 부하 시스템을 갖는다. 데이터 습득부분에서는 3-상 전류를 PC로전송하기 위해 NI사의 PCI-6251 DAQ 보드를 사용하여 20kHz의 샘플링 데이터를 검출한다. 데이터 취득은 PC상에서 LabVIEW 7.1 프로그램을 이용하여 고장상태별로 데이터를 취득하였다. 표 1에서는 진단시스템의 기본적 구성요소들의 사양을 나타냈다.

그림 3은 전체 실험장비들의 사진이다. 그림 3에서 볼 수 있듯이 진단 실험시스템은 많은 추가 요소들을 가지고 있다. 먼저 그림 3의 좌측 상단에 있는 인버터는 인버터 구동을 위해 설치하였으며, 구동 전류의 불평형 및 변동을 위해 가변전압기와 가변저항기를 설치하였다. 또한, 실제 산업 현장에서 유도전동기에 부과되는 기계적 부하를 변동시키기 위해 다이나모메타를 설치하였다. 다이나모메타는 맴돌이 전류방식(Eddy Current Type)의 제동기를 사용하여 부하의 크기를 변동시키는 장치이다. 기타 몇몇의 안전장치와 그림에 나와 있지는 않으나 입력 전원단에 정확한 전원공급을 위해 AVR를 설치하였다.

표 1. 진단 시스템의 사양
Table 1. Specification of the system

Comp.	Spec.
Induction motor	0.4kW(1/2 HP), 220V, 60Hz 4p, 1700rpm, Efficient: 65%
Current sensor	Rating current: ±10A, Output: ±4V
Data acquisition	500Ks/s, 16bit, 4channel
Load equipment	Brake system of eddy current type
PC	Pentium 4, 2.8GHz

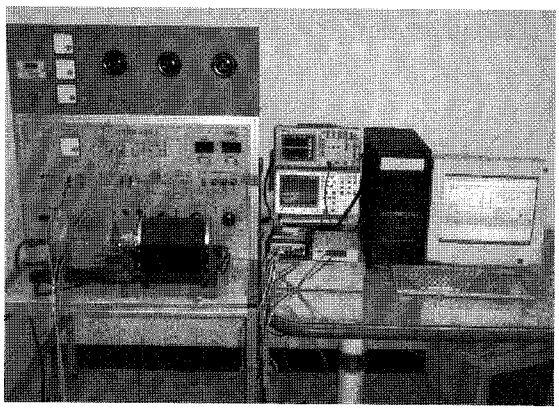

그림 3. 전체 실험장치의 구성
Fig. 3. Experimental setup

3.2 고장의 범위 및 데이터 취득

일반적으로 유도전동기의 고장은 수많은 부분에서 다양한 형태로 나타나지만, 제안한 온라인 고장진단 기법의 검증에 사용한 고장의 범위는 정상 데이터(H1), 전압불평형(F1), 베어링 고장(F2), 회전자 고장(F3), 고정자 고장(F4), 회전자 불평형(F5) 등 여섯 가지 경우를 고려한다. 그림 4에서는 유도전동기의 고장부위 일부를 나타냈다. 고장데이터 중에서, 그림 4(a)에 보인 베어링 고장은 외곽 레일부분의 한 부위에 압착을 가하여 고장을 발생시켰다. 또한 그림 4(b)에 보인 회전자는 Zhongming[7] 등이 실험한 방법과 같이 회전자의 편심에 드릴로 구멍을 내어 고장을 발생시켰다. 회전자 고장은 그림 4(c)에 나타낸 바와 같이 회전자 권선의 일부를 단락시켰다. 또한 회전자 불평형은 그림 4(d)에 보인 바와 같이 회전자 끝단 부위에 위치한 링을 제거하여 고장패턴을 취득하였다. 이외에도 한 상에 3[%]의 불평형 전압을 인가하여 전압불평형 데이터를 취득하였다.

데이터 취득은 LabVIEW 상에서 영점교차점을 이용하여 1초마다 습득하는 10 주기의 전류신호에 대하여 고장진단을 수행한다. 그림 5에 나타낸 LabVIEW의 프로그램을 요약하면, DAQ 보드로부터 들어온 입력 데이터들을 주어진 일정 시간마다 한 주기의 전류신호를 취득하였다. 데이터 취득시 샘플링 주파수의 설정은 시스템 성능에 영향을 미칠 수 있는 중요한 인자로서 본 논문에서는 20kHz로 설정하였으며, 따라서 한 주기 당 334개의 샘플을 취득하였다. 실측 데이터는 고장상태별로 부하를 무부하, 0.04kg·m, 0.08kg·m, 0.12kg·m, 0.16kg·m로 5단계로 분류하여 고장상태별로 10주기를 갖는 200개의 데이터(부하상태 5 × 40샘플)를 취득하였다. 따라서 총 1200개의 데이터를 취득한 후 600개는 학습데이터로 사용하고, 나머지 600개는 검증데이터로 사용하였다.

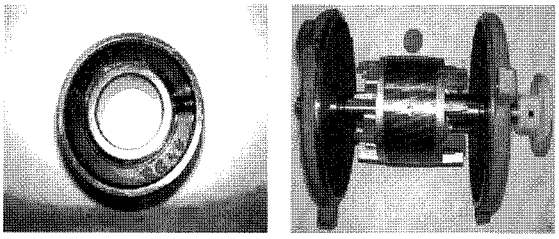

(a) 베어링 고장 (b) 회전자 고장

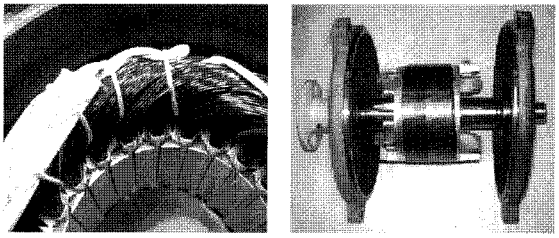

(c) 고정자 고장 (d) 회전자 불평형

그림 4. 유도 전동기의 고장
Fig. 4. Faults of induction motors
(a) bearing fault (b) rotor fault
(c) stator fault (d) rotor unbalance

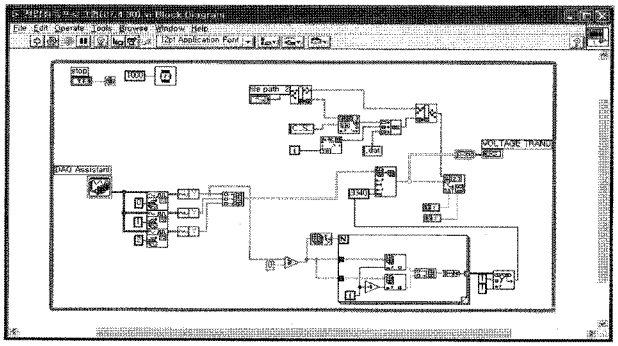

그림 5. LabVIEW를 이용한 데이터 취득 프로그램
Fig. 5. LabVIEW program for data acquisition

3.3 실험 결과

본 논문에서는 시간정보를 갖는 전류신호를 DFT에 의해 주파수 공간에서의 변환 및 LDA를 이용한 고장특성별 주파수 특징 추출방법과 웨이블렛을 이용한 시간-주파수 공간에서의 고장진단 기법을 개발하였다. 최종 단계에서는 주파수 정보와 시간-주파수 정보를 효과적인 융합알고리즘에 의해 고장 진단이 수행된다.

제안된 방법의 타당성을 검증하기 위해 다양한 방법들과 성능을 분석하고자 한다. 그림 6 및 표 2에서는 적용방법 및 고장상태에 대한 진단결과를 나타냈다. 고장상태별로 진단결과를 나타낸 표 2에서 볼 수 있는 바와 같이 정상상태(H1)의 경우 LDA에 의한 진단방법이 97[%]을 보여 가장 우수한 성능을 나타낸 반면에 웨이블렛에 의한 진단방법이 85[%]을 보여 가장 저조한 성능을 나타냈다. 전압불평형(F1)은 웨이블렛과 LDA에 의한 방법이 100[%]로 가장 우수한 성능을 나타낸 반면에 DFT+PCA에 의한 진단 방법이 95[%]로 가

장 저조한 성능을 나타냈다. 베어링고장(F2)은 PCA와 DFT+LDA에 의한 방법이 100[%]을 보여 가장 우수한 성능을 나타낸 반면에 PCA에 의한 진단방법이 95[%]로 가장 저조한 성능을 나타냈다. 회전자고장(F3)은 DFT+LDA에 의한 방법이 99[%]을 보여 가장 우수한 성능을 나타낸 반면에 웨이블렛에 의한 진단방법이 78[%]로 가장 저조한 성능을 나타냈다. 고정자고장(F4)은 DFT+LDA에 의한 방법이 99[%]을 보여 가장 우수한 성능을 나타낸 반면에 PCA에 의한 진단방법이 74[%]로 가장 저조한 성능을 나타냈다. 회전자불평형(F5)은 DFT+LDA에 의한 방법이 99[%]을 보여 가장 우수한 성능을 나타낸 반면에 웨이블렛에 의한 진단방법이 83[%]로 가장 저조한 성능을 나타났다.

이러한 결과를 종합해 보면, 시간영역에서 LDA를 적용한 경우 정상(H1)과 전압불평형(F1)에 우수한 성능을 보인 반면에 회전자고장(F3), 고정자고장(F4) 및 회전자불평형(F5)에 대해서는 진단성능이 저조한 것으로 나타났다. 반면에 DTF에 의해 시간정보를 갖는 전류신호를 주파수 영역으로 변환한 후에 LDA를 적용한 DFT+LDA는 정상(H1)과 전압불평형(F1)에 대해서는 저조한 성능을 보인 반면에 회전자고장(F3), 고정자고장(F4) 및 회전자불평형(F5)에 대해서는 진단성능이 우수한 것으로 나타났다.

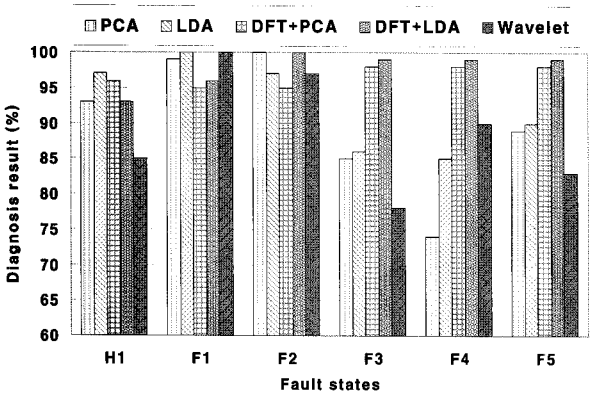

그림 6. 적용방법과 고장상태에 따른 진단율
Fig. 6. Fault diagnosis result according to applied methods and fault states

표 2. 적용방법별 진단결과
Table 2. Fault diagnosis result by each method
[unit : %]

	H1	F1	F2	F3	F4	F5	인식률
PCA	93	99	100	85	74	89	90
LDA	97	100	97	86	85	90	92.5
DFT+PCA	96	95	95	98	98	98	96.7
DFT+LDA	93	96	100	99	99	99	97.7
Wavelet	85	100	97	78	90	83	88.8
융합기법-A	100	100	100	99	99	100	99.7
융합기법-B	100	100	100	100	100	100	100

본 논문에서는 융합기법에 의한 고장진단 성능을 개선하는 방법을 제안하였다. 융합방법으로는 시간영역에서 우수한 성능을 보인 LDA방법과 주파수 공간에서 우수한 성능을 나타낸 DFT+LDA를 융합하는 방법(융합방법-A)와 성능이 저조하게 나타났지만 시간-주파수 정보를 갖는 웨이블렛과 DFT+LDA를 융합하는 방법(융합방법-B)를 고려하였다.

표 3. 고장자고장(F4)데이터에 대한 거리척도값
Table 3. Distance measure values for a rotor fault data

	H1	F1	F2	F3	F4	F5	결과
LDA	2.47	4.42	1.94	0.62	0.79	1.35	F3
DFT+LDA	10.24	11.96	11.45	2.70	2.77	7.71	F3
융합-A	12.71	16.38	13.39	3.32	3.56	9.06	F3
Wavelet	0.15	5.98	2.15	0.28	0.11	0.70	F4
DFT+LDA	10.24	11.96	11.45	2.71	2.77	7.71	F3
융합-B	10.39	17.94	13.6	2.99	2.88	14.71	F4

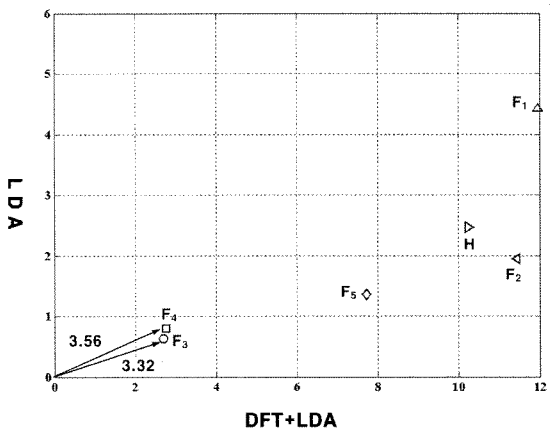

(a) LDA와 DFT+LDA에 의한 융합결과

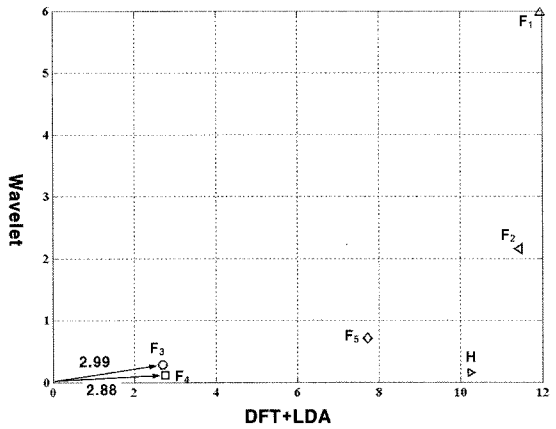

(b) 웨이블렛과 DFT+LDA에 의한 융합결과

그림 7. 고장상태 및 융합방법에 따른 거리척도 I
Fig. 7. Distance measure according to fault states and fusion methods

실험결과, 융합방법-A는 99.7[%]을 나타냈으며, 융합방법-B는 100[%]로 나타내 웨이블렛과 DFT+LDA를 적용한 융합방법이 가장 우수한 성능을 나타냈다. 이와 같이 인식률이 저조한 웨이블렛기반 방식이 융합에 기여하는 정도를 분석하

기 위하여 표 3 및 그림 7에 고정자 고장(F4) 데이터에 대한 고장상태별 기준특징값과의 유클리디언 거리비교를 통해 산출된 거리척도값을 나타냈다.

표 3 및 그림 7에서 보는 바와 같이 LDA와 DFT+LDA을 적용한 결과 고정자고장(F4) 데이터를 회전자고장(F3)으로 진단하였으며, 그 결과 융합을 하더라도 고정자고장(F4) 데이터를 회전자고장(F3)으로 진단하였다. 반면에 DFT+LDA을 적용한 결과가 고정자고장(F4) 데이터를 회전자고장(F3)으로 진단하였다 하더라도 웨이블렛에 의한 방법이 고정자고장(F4) 데이터를 고정자고장(F4)로 진단하여 최종 융합을 하였을 경우 고정자고장(F4) 데이터를 고정자고장(F4)으로 진단하였다. 이러한 결과는 고정자고장(F4)인 경우 LDA에 의한 방법보다 웨이블렛에 의한 방법이 진단 성능이 우수한 것에 기인한 것으로 분석된다.

표 4 및 그림 8에서는 정상(H1)데이터에 대한 고장상태별 거리 척도값을 나타냈다. 표 및 그림으로부터 웨이블렛을 적용한 결과 정상(H1)데이터를 고정자고장(F4)으로 진단하였다. 또한, DFT+LDA를 적용한 결과 정상(H1)데이터를 전압불평형(F1)으로 진단하였다. 그러나 웨이블렛과 DFT+LDA를 적용한 결과 정상(H1)데이터를 정상(H1)으로 진단하여 융합을 함으로써 성능이 향상됨을 확인할 수 있다. 즉, 웨이블렛 기법이 진단율은 낮지만 웨이블렛이 잘 분류하는 영역과 DFT+LDA방법이 잘 분류하는 영역이 서로 보완적으로 작용하여 인식률이 향상된 것으로 분석할 수 있다.

표 4. 정상(H1)데이터에 대한 거리척도값
Table 4. Distance measure values for a healthy data

	H1	F1	F2	F3	F4	F5	결과
Wavelet	0.17	3.71	3.12	0.59	0.14	7.47	F4
DFT+LDA	2.61	2.06	8.70	8.60	12.25	10.43	F1
융합-B	2.78	5.77	11.82	9.19	12.39	17.90	H1

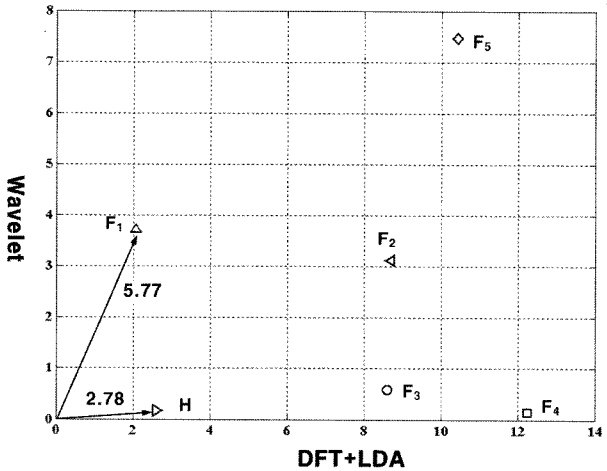

그림 8. 고장상태 및 융합방법에 따른 거리척도 II
Fig. 8. Distance measure according to fault states and fusion methods

4. 결 과

본 논문에서는 효과적인 DFT와 웨이블렛을 이용한 진단 추출방법과 효과적인 융합방법에 의한 유도전동기 고장진단 알고리즘을 제안하였다. 제안된 방법은 DFT에 의해 실시간 전류신호를 주파수 공간으로 변환한 후 선형판별분석기법에 의해 고장상태를 특징을 추출한다. 또한, 웨이블렛 다해상도 기법에 의해 전류신호의 시간-주파수 정보를 갖는 특징을 추출한다. 최종 분류단계에서는 두 가지 특성을 융합함으로써 효과적으로 진단이 수행된다. 제안된 방법의 타당성을 보이기 위해 유도 전동기 고장진단 장치를 설계 및 제작한 후, 데이터 취득장치에 의해 실측 데이터를 이용하여 실험한 결과, 제안된 융합방법이 웨이블렛만을 적용한 경우보다 11.2[%], DFT+LDA만을 적용한 경우보다 2.3[%] 성능이 향상된 것으로 나타났다. 따라서 제안된 방법의 경우 다른 분류기법에 비해 우수한 성능을 보임을 확인할 수 있었다.

참 고 문 헌

[1] S. Wu, T. Chow, "Induction machine fault detection using SOM-based RBF neural network," *IEEE Trans. Ind. Elect.*, Vol. 51, No. 1, pp. 183-194, 2004.

[2] W. T. Thomson, M. Fenger, "Current signature analysis to detect induction motor faults," *IEEE Ind. Applicat. Magazine*, pp. 26-34, July/August 2001.

[3] Nejjari, M. H. Benbouzid, "Monitoring and diagnosis of induction motors electrical faults using a current Park's vector pattern learning approach," *IEEE Trans. Ind. Applicat.*, Vol. 36, No.3, pp. 730-735, 2000.

[4] Zidani et al., "Induction motor stator faults diagnosis by a current Concordia pattern-based fuzzy decision system," *IEEE Trans. Energy Conversion*, Vol. 18, No. 4, pp. 469-475, December 2004.

[5] M. Haji and H. A. Toliyat, "Pattern recognition - a technique for induction machines rotor broken bar detection," *IEEE Trans. on Energy Conversion*, Vol. 16, Issue 4, pp. 312-317, 2001.

[6] A. M. Trzynadlowski and E. Ritchie, "Comparative investigation of diagnostic media for induction motors : a case of rotor cage faults," *IEEE Trans. on Industrial Electronics*, Vol. 47, No. 5, pp. 1092-1099, 2000.

[7] Zhongming Ye, Bin Wu, and Alireza Sadeghian, "Current Signature Analysis of Induction Motor Mechanical Faults by Wavelet Packet Decomposition," IEEE Trans. on Industrial Electronics, Vol. 50, No. 6, 2003.

[8] Jang-Hwan Park, Dae-Jong Lee, Myung-Geun Chun, "Fault Diagnosis for Induction Machines Using Kernel Principal Component Analysis", *ISNN2006, LNCS 3973*, pp.406-413, 2006.

저 자 소 개

권만준(Man-Jun Kwon)
1989년 부산대학교 전자공학과(학사)
1991년 한국과학기술원 전기 및 전자공학과(공학석사)
2003년~현재 충북대학교 제어계측공학과 박사수료.

관심분야 : 전동기 고장진단, 생체인식, 얼굴인식, 임베디드 프로그래밍
Phone : 041-939-3186
Fax : 041-932-6173
E-mail : mjkwonkr@yahoo.co.kr

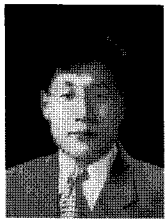

이대종(Dae-Jong Lee)
1995년 충북대학교 전기공학과(학사)
1997년 충북대학교 전기공학과(공학석사)
2002년 충북대학교 전기공학과(공학박사)
2004년~2005년 University of Alberta Postdoc.
2006년~현재 충북대학교 BK21 충북정보기술사업단 초빙 조교수

관심분야 : 음성신호처리, 얼굴인식, 다중생체인식, 고장진단
Phone : 043) 261-2388
Fax : 043) 268-2386
E-mail : djmidori@empal.com

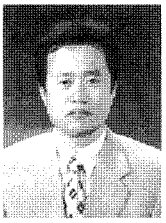

박성무(Sung-Moo Park)
1980년 충북대학교 전기공학과(학사)
1982년 충북대학교 전기전자공학과 (공학석사)
2006년 충북대학교 전기전자공학과 (공학박사)
1994년~현재 한국폴리텍 Ⅳ대학 청주캠퍼스 전기과 교수

관심분야 : 전기기기 고장진단, 인버터 속도제어, 패턴분류
Phone : 043) 279-7414
Fax : 043) 279-7477
E-mail : smp@kopo.ac.kr

전명근(Myung-Geun Chun)
1987년 부산대학교 전자공학과(학사)
1989년 한국과학기술원 전기 및 전자공학과(공학석사)
1993년 한국과학기술원 전기 및 전자공학과(공학박사)
1993년~1996년 삼성전자 자동화연구소선임연구원
2000년~2001년 University of Alberta 방문교수
1996년~현재 충북대학교 전기전자 컴퓨터공학부 교수

관심분야 : Biometrics, 감정인식, 지능시스템
Phone : 043) 261-2388
Fax : 043) 268-2386
E-mail : mgchun@chungbuk.ac.kr