

계층구조의 분류기에 의한 유도전동기 고장진단

Fault Diagnosis of Induction Motor by Hierarchical Classifier

이 대 종, 송 창 규, 이 재 경, 전 명 근*

(Dae-Jong Lee, Chang-Kyu Song, Jae-Kyung Lee, and Myung-Guen Chun)

Abstract : In this paper, we propose a fault diagnosis scheme for induction motor by adopting a hierarchical classifier consisting of k-Nearest Neighbors(k-NN) and Support Vector Machine(SVM). First, some motor conditions are classified by a simple k-NN classifier in advance. And then, more complicated classes are distinguished by SVM. To obtain the normal and fault data, we established an experimental unit with induction motor system and data acquisition module. Feature extraction is performed by Principal Component Analysis(PCA). To show its effectiveness, the proposed fault diagnostic system has been intensively tested with various data acquired under the different electrical and mechanical faults with varying load.

Keywords : fault diagnosis, induction motor, PCA, SVM, hierarchical classifier

I 서론

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 전동신호 모니터링[1]과 MCSA(Motor Current Signal Analysis)[2-4]에 의해서 이루어진다. 과거에는 전동 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 절연 상태를 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], 전류

신호의 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 시간 축과 주파수 공간 내에서 해석이 가능한 웨이블렛을 이용하여 특징을 추출하는 방법이 제안되었다[7-9]. 이 외에도 주성분분석기법(PCA: Principal Component Analysis)을 이용하여 특징을 추출하는 방법이 사용되고 있다[10]. 그러나 주성분분석기법은 모든 입력차원의 선형성에 기반을 두고 있기 때문에 선형 특성에 대해서는 우수한 결과를 나타내나 비선형특성을 갖는 데이터에 대해서는 최적의 변환행렬을 구할 수 없는 문제점을 지니고 있다. 이러한 이유로 선형분류기인 거리 유사도 방법 외에 인공신경망과 퍼지 논리에 기반을 둔 진단 알고리즘이 적용되었다[3,4].

SVM(Support Vector Machine)은 Vapnik에 의해 제안된 알고리즘으로 경험적 위험을 최소화하는 학습원리인 “경험적 위험 최소화”에 기반을 둔 신경회로망과는 달리 “구조적 위험 최소화”를 이용하여 일반화 오류를 감소시키는 방법에 기반을 두고 있다. 또한 신경회로망과 같은 접근방법들처럼 SVM 역시 비선형 패턴, 곡선함수 추정 등의 다양한 분야에 효과적으로 수행 할 수 있는 능력을 가지고 있다[11-14]. 따라서 본 논문에서는 주성분분석기법에 의해 입력전류의 특징을 추출한 후, k-NN과 SVM으로 구성된 계층구조의 분류기에 의해서 인버터 구동 유도 전동기의 고장진단 기법을 제안하고자 한다. 제안된 방법의 타당성을 검증하기 위하여 다양한 방법들과 비교가 병행 되었으며, 주된 비교 방법으로서 웨이블렛, 선형판별분석기법 등을 고려하였다. 유도전동기 고장진단 장치를 설계 및 제작한 후, 데이터 취득장치에 의해 실측 데이터를 이용하여 제안된 방법이 기존 방법에 비해 우수한 결과를 보임을 검증 하고자 한다.

* 책임저자(Corresponding Author)

논문접수 : 2007. 1. 25., 채택확정 : 2007. 2. 17.

이대종 : 충북대학교 충북정보기술사업단 초빙조교수

(bigbell@chungbuk.ac.kr)

송창규 : 충북대학교 충북정보기술사업단 Postdoc
(sckyu@chungbuk.ac.kr)

이재경 : 충주대학교 정보제어공학과 교수
(jklee@cjnu.ac.kr)

전명근 : 충북대학교 전기전자컴퓨터공학부 교수
(mgchun@chungbuk.ac.kr)

※ 본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2007-2-046) 주관으로 수행된 과제임.

II. SVM을 이용한 패턴분류

그림 1에서는 두 개의 클래스로 구성되어 있고 데이터가 선형분리 가능한 2차원 데이터인 경우 SVM에 의한 분류과정의 예를 나타냈다. 그림 1에서 보인 입력패턴인 경우 두 클래스를 분류할 수 있는 초평면은 무수히 많이 존재하는데 그 중에서 최적의 초평면을 결정하고자 하는 것이 SVM의 목적이다. SVM에서는 최적을 정의하기 위해 마진(margin)의 개념을 도입하였다. 마진은 초평면과 가장 인접한 지지벡터들(support vectors)과의 거리를 나타내는데 그림 1에서 두 접선 사이의 거리가 된다. 그림 1에서 실선은 초평면이고, 초평면과 나란하게 있는 접선들 사이의 거리가 마진이다. SVM은 이 마진이 최대가 되도록 초평면을 학습하고 이 마진을 사용해서 분류작업을 수행한다[11].

SVM에서는 지지벡터만 중요한 역할을 하게 되며 다른 나머지 데이터는 무시됨을 알 수 있다. 여기서 마진은 다음과 같이 나타낼 수 있다.

$$d = \frac{2}{\|w\|}, \text{ 여기서, } (w^T \cdot x) + b = \pm 1 \quad (1)$$

따라서 SVM 학습은 최적화 문제로 바꾸어 처리 가능하다. 모든 데이터가 초평면에서의 거리가 최소한 1이라고 가정한다면 학습 데이터 집합 (x_i, y_i) 에 대해 다음과 같은 제약조건하에서 $\|w\|$ 가 최소가 되도록 최적화 알고리즘을 이용하여 w 와 b 를 찾아낸다.

$$y_i [(w^T \cdot x_i) + b] \geq 1, i = 1, \dots, l \quad (2)$$

SVM은 기본적으로 선형분리가 가능한 문제에서 출발하였지만 모든 문제가 선형적으로 분리될 수는 없다. 이처럼 입력데이터가 선형 불가능할 경우 입력공간을 분리하는 비선형 결정면을 이용하게 되는데, 비선형 결정면의 식을 분석적으로 계산해 낸다는 것은 매우 어려운 일이다. 이런 경우 SVM에서는 커널함수(kernel function) $k(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$ 를 이용하여 입력벡터 x_i 를 고차원 특징벡터로 변형한 후, 선형의 경계선을 찾는 문제로 전환한다. 이처럼 커

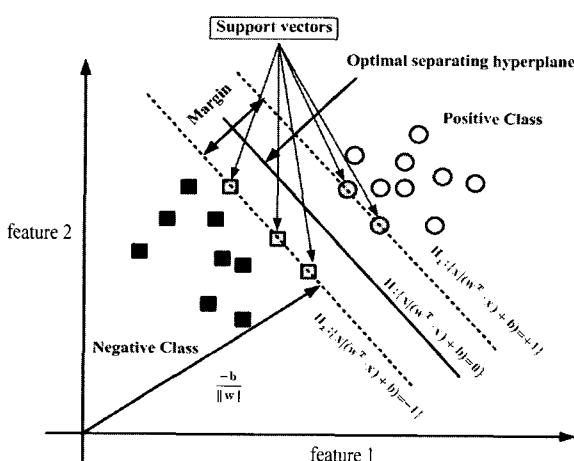


그림 1. SVM에 의한 패턴분류.

Fig. 1. Pattern classification by SVM.

널함수를 이용하면 입력벡터를 고차원의 특징벡터로 투영시킴으로써 내적에 대한 계산만을 필요하게 되므로 계산의 복잡함을 줄일 수 있다. 즉, 낮은 차원의 비선형 함수는 높은 차원에서 선형 함수로 근사화 시킬 수 있으므로 특징공간에서 최적의 초평면을 구축하는 것은 결국 입력공간에서 비선형 결정함수를 이용하여 최적의 선형함수를 결정하는 것과 동일하게 된다. 본 논문에서는 (3)과 같이 방사기저함수 RBF(Radial Basis Function) 커널함수를 사용하였다.

$$k(x, y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) \quad (3)$$

III. 계층구조 분류기에 의한 유도전동기 고장진단

그림 2에서는 본 논문에서 제안된 유도전동기 진단 알고리즘의 구성도를 나타냈다. 그림 2에서 보는 바와 같이, 선형판별분석기법(PCA:Principal Component Analysis)에 의해 입력 전류신호를 저 차원으로 축소한 후, 간단한 k-NN 분류기에 의해 고장을 진단한 후, 2차적으로 서포트 벡터머신에 의해 최종 진단을 하는 계층구조의 분류기에 의해 진단이 이루어진다. 주성분분석기법에 의한 특징추출과정을 단계별로 살펴보면 다음과 같다.

- 단계 1: 측정된 학습용 전류신호를 1차원 열벡터로 변환한 후 (4)에 의해 전체 신호의 평균을 계산한다.

$$m = \frac{1}{P} \sum_{i=1}^P x_i \quad (4)$$

- 단계 2: 측정된 전류신호에 대한 공분산행렬을 (5)에 의해 구한다.

$$\Omega = \bar{X} \bar{X}^T \quad (5)$$

$$\bar{X} = [\bar{x}_1, \bar{x}_2, \dots, \bar{x}_P], \bar{x}_i = x_i - m$$

- 단계 3: (5)에 의해 계산된 공분산행렬 Ω 의 고유값 λ 와 λ 에 대응하는 고유벡터 v_j 를 (6)에 의해서 계산한다.

$$\Omega v_j = \lambda v_j \quad (6)$$

- 단계 4: 고유벡터 v_j 를 고유값의 크기순으로 나열한 후 학습신호 x_i 에 대한 특징벡터 z_i 를 구한다. (7)에서 알 수 있는 바와 같이 입력신호에 대한 특징벡터는 공분산에 대한 고유벡터를 이용하여 PCA로 변환된 공간으로 투영함으로써 얻을 수 있다.

$$z_i = v_j^T (x_i - m) \quad (7)$$

- 단계 5: 인식하고자 하는 입력전류(검증데이터)를 주성분분석기법에 의해 특징 추출한다.

$$z'_i = v_j^T (x'_i - m) \quad (8)$$

여기서, x'_i 은 인식하고자 하는 유도전동기의 입력전류를 나타낸다.

제안된 방법의 기본 개념을 설명하기 위해 실험 데이터에서 취득된 실측데이터를 이용하여 주성분 분석기법에 의

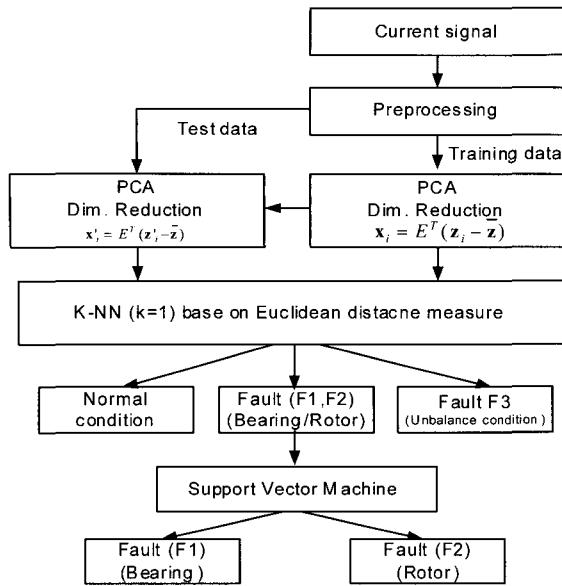


그림 2. 제안된 유도전동기 진단 알고리즘.

Fig. 2. Proposed detection method for induction motors.

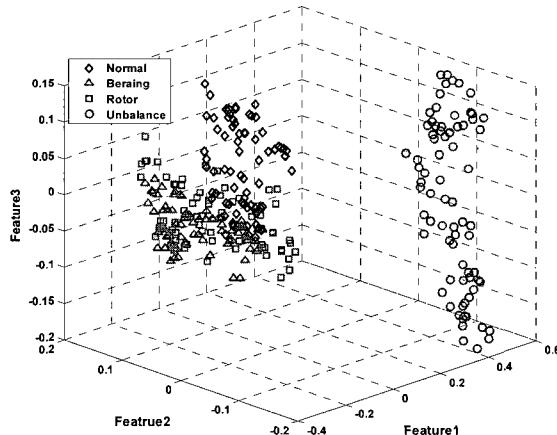


그림 3. PCA에 의해 얻어진 특징벡터.

Fig. 3. Features obtained by principal component analysis.

해 저차원으로 축소된 결과를 그림 3에 나타냈다. 여기서, 진단 분류로는 정상데이터, 베어링 고장, 회전자 고장, 불평형 등 4가지의 상태를 고려한다. 이에 대한 자세한 설명은 실험부분에 설명하고자 하며, 여기서는 제안된 방법의 기본 개념 및 접근 타당성에 대하여 설명한다.

그림 3에서 보는 바와 같이 정상데이터와 불평형 고장 데이터는 다른 고장데이터와 차별성이 있는 반면에, 베어링 고장과 회전자 고장은 두 가지 고장의 특성이 유사하여, 특징벡터들도 서로 겹쳐져 있는 특성이 있음을 확인할 수 있다. 표 1에서는 주성분분석기법에 의해 축소된 차원이 3인 경우와 4인 경우에 대하여 간단한 분류기인 유클리디안 거리기반 k-NN($k=1$) 분류기에 의해 진단한 결과를 나타냈다. 표 1에서 보는 바와 같이 축소된 특징벡터의 수가 4인 경우에 정상상태(H)와 불평형 상태(F3)은 진단 성능이 100%로 나왔으나, 베어링 고장(F2)과 회전자고장(F3)은 매우

표 1. PCA와 k-NN에 의한 인식결과.

Table 1. Classification results by PCA and k-NN.

Fault	Feature dimension : 3				Feature dimension: 4			
	H	F1	F2	F3	H	F1	F2	F3
H	66	0	9	0	75	0	0	0
F1	2	54	19	0	0	57	18	0
F2	2	12	61	0	0	12	63	0
F3	0	0	0	75	0	0	0	75

낮은 인식성능을 보였다. 이 결과로 부터 정상 데이터와 불평형 데이터는 간단한 분류기만으로도 진단이 가능하나, 베어링 고장과 회전자 고장은 분류를 위해 성능이 우수한 분류기의 개발이 요구됨을 알 수 있다. 따라서 본 연구에서는 계층구조의 분류기에 의해 유도전동기의 진단성능을 향상시키고자 한다.

IV. 실험 및 결과

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 전동센서의 구동회로, 그리고 전기적 브레이크 기능을 갖는 부하 시스템을 갖는다. 데이터 습득부분에서는 3-상 전류를 PC로 전송하기 위해 NI사의 PCI-6251 DAQ 보드를 사용하여 10kHz의 샘플링 데이터를 검출한다. 데이터 취득은 PC 상에서 LabVIEW 7.1 프로그램을 이용하여 고장 상태별로 데이터를 취득하였다. 표 2는 진단시스템의 기본적 구성요소들의 사양을 보여준다.

그림 4는 전체 실험장비들의 사진이다. 그림 4에서 볼 수 있듯이 진단 실험시스템은 많은 추가 요소들을 가지고 있다. 먼저 그림 4의 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 전원공

표 2. 진단 시스템의 사양.

Table 2. Specification of the system.

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

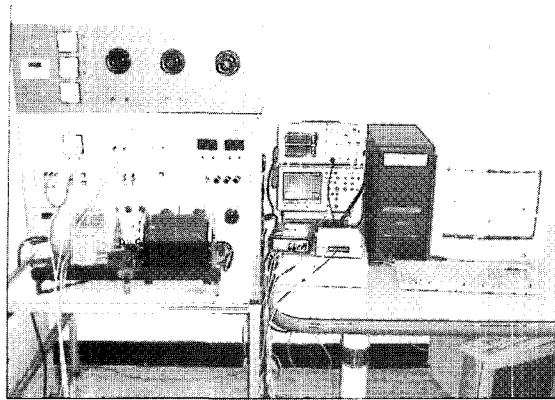


그림 4. 전체 실험장치의 구성.

Fig. 4. Experimental setup.

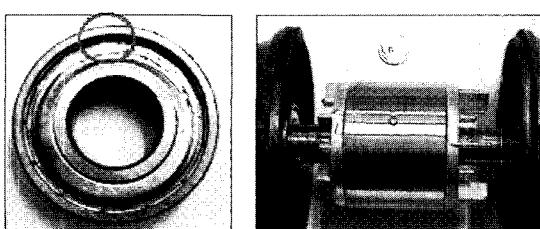
급을 위해 AVR를 설치하였다.

2. 고장의 범위 및 데이터 취득

일반적으로 유도전동기의 고장은 수많은 부분에서 다양한 형태로 나타나지만, 제안한 온라인 고장진단 기법의 검증에 사용한 고장의 범위는 정상 데이터, 베어링 고장, 회전자 고장, 전압 불평형 등 네 가지 경우를 고려한다. 고장 데이터 중에서, 그림 5(a)에 보인 베어링 고장은 외곽 레일 부분의 한 부위에 압착을 가하여 고장을 발생시켰다. 또한 그림 5(b)에 보인 회전자는 Zhongming[8]와 Bossio[15] 등이 실험한 방법과 같이 회전자의 편심에 드릴로 구멍을 내어 고장을 발생시켰다.

베어링 고장과 회전자 고장 등과 같은 물리적인 고장 외에 전압 불평형에 의한 영향을 고려할 필요가 있다. 이것은 실제 불평형 상에 관계한 전기적 고장들과 같이 전자기 속(flux)을 달라지게 하므로, 고정자 코어에 작용하는 역기전력을 변하게 하며, 입력전류 값을 변화시킨다. 이와 같은 전기적 고장을 구현하기 위해, 그림 4의 상단에 위치한 가변저항기를 전동기 입력 단에 설치하여 한 상에 3%의 불평형 전압을 발생시켰다.

데이터 취득은 그림 6에서 보는 바와 같이 LabVIEW 상에서 영점교차점을 이용하여 1초마다 습득하는 1주기의 전류신호에 대하여 고장진단을 수행한다. 먼저, LabVIEW의 프로그램을 요약하면, DAQ 보드로부터 들어온 입력 데이터들을 주어진 일정 시간마다(1 초) 한 주기(10kHz에서 167 개) 샘플을 검출하였다. 실측 데이터는 고장상태별로 부하



(a) 베어링 고장

(b)회전자고장

그림 5. 유도전동기의 고장부위.

Fig. 5. Fault parts.

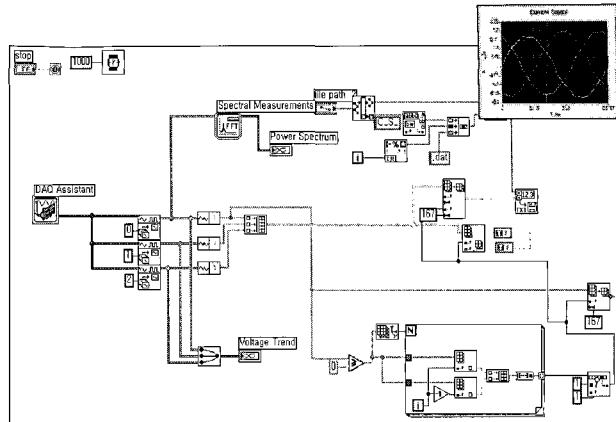


그림 6. Labview를 이용한 데이터 취득 프로그램.

Fig. 6. Labview program for data acquisition.

를 무부하, 0.04 kg·m, 0.08 kg·m, 0.12 kg·m, 0.16 kg·m로 5단계로 분류하여 총 600개의 데이터(4상태 × 5부하상태 × 30주기)를 취득하였다. 즉 고장상태별로 150개의 데이터를 취득하였으며, 이 중에서 75개는 훈련데이터로 사용하고, 나머지 75개는 검증데이터로 사용하였다.

3. 실험 결과

본 논문에서 제안된 진단알고리즘을 수행하는 첫 번째 단계는 주성분 분석기법을 이용하여 입력신호의 특징을 추출하는 과정이다. 주성분 분석기법을 적용하여 특징을 추출할 경우 몇 개의 차원으로 축소할지를 결정해야만 한다. 본 논문에서는 그림 7에서 보는 바와 같이 특징의 수를 10개에서 80개 까지 5씩 증가시켜가면서 진단결과를 분석한 결과 가장 우수한 진단 성능을 보인 25개의 특징을 추출하였다. 베어링고장과 회전자고장의 분류를 위한 SVM에 사용된 커널함수로는 다양한 논문에서 우수한 결과를 보인 방사기저함수를 사용하였으며 Matlab 6.0에서 실행하였다[16].

실험결과를 표 3에 나타냈다. 표 3에서 보는 바와 같이 주성분분석기법에 의해 특징을 추출한 후, k-NN 분류기에 의해 진단한 결과 정상데이터와 전압불평형 데이터의 경우

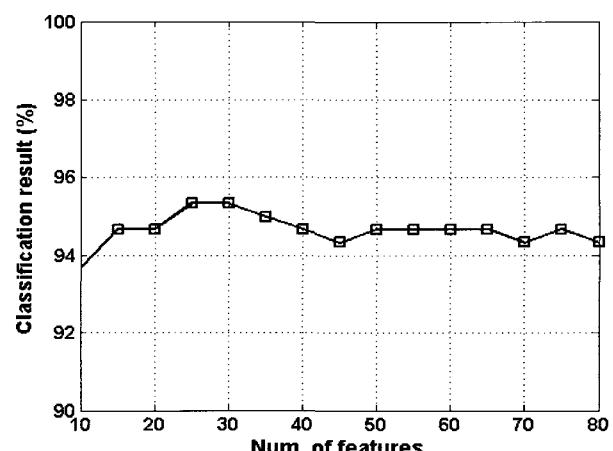


그림 7. 주성분분석의 특징개수에 따른 인식률.

Fig. 7. Classification results according to the number of features.

표 3. 적용방식별 진단결과.

Table 3. Comparison of each method [%].

Classifier	Feature	N	F1	F1	F3	Mean
k-NN	PCA	100	94.7	86.7	100	95.3
	Wavelet	100	73.3	70.7	100	86.0
MLP	PCA	98.7	82.7	2.7	100	71.0
	Wavelet	100	69.3	56.0	100	81.3
RBF	PCA	100	78.7	44.4	100	80.7
	Wavelet	94.7	84.0	61.3	100	85.0
Multi-SVM	PCA	94.7	84.0	81.3	100	91.3
	Wavelet	97.3	85.3	68.0	98.7	87.3
Proposed method	PCA	100	96.0	92.0	100	97.0
	Wavelet	100	76.0	81.3	100	89.3

100%의 인식결과를 보였으나, 베어링 고장인 경우 94.7%, 회전자 고장의 경우 86.7%로 인식률이 낮게 나타났다. 또한, 선형판별분석기법과 웨이블렛 변환에 의하여 특징을 추출하여 인식률을 분석한 결과 주성분분석기법에 의한 인식결과가 가장 효과적인 것으로 나타났다. 또한, 다중신경회로망과 방사기저함수 등의 인공지능 기법에 의한 분류기법을 적용해 본 결과 k-NN 분류기보다 더 낮은 인식결과를 나타났다. 이와 같이 인식률이 낮게 나타나는 이유로는 베어링 고장과 회전자 고장간의 특징벡터들이 서로 겹쳐있는 영역에 의한 것으로 분석된다. 최종적으로 인식률을 향상시키기 위하여, 계층구조의 분류기법을 적용한 결과 97.0%의 인식결과를 보여 k-NN 분류방법에 비해 1.7%의 성능향상을 보였다. 따라서, 제안된 방법의 경우 다른 분류기법에 비해 우수한 성능을 보임을 확인할 수 있었다.

V. 결론

본 논문에서는 PCA에 의한 특징추출과 k-NN과 SVM에 기반을 계층구조의 분류기에 의한 유도전동기의 고장진단 알고리즘을 제안하였다. 제안된 방법은 우선적으로 선형판별분석기법에 의해 입력 전류신호를 저 차원으로 축소한 후, 간단한 k-NN 분류기에 의해 고장을 진단한 후, 2차적으로 서포트 벡터머신에 의해 최종 진단을 하는 계층구조의 분류기에 의해 진단이 이루어진다.

제안된 방법의 타당성을 보이기 위해 유도 전동기 고장진단 장치를 설계 및 제작한 후, 데이터 취득장치에 의해 실측 데이터를 이용하여 실험한 결과, 주성분분석기법에 의해 특징을 추출한 후, k-NN 분류기에 의해 진단한 결과 정상데이터와 전압 불평형 데이터의 경우 100%의 인식결과를 보였으나, 베어링 고장인 경우 94.7%, 회전자 고장의 경우 86.7%로 나타나 베어링 고장과 회전자고장에 대해서는 상대적으로 진단성능이 낮게 나타났다. 이러한 문제점을 해결하기 위하여 SVM을 이용한 계층구조의 분류기법을 적용한 결과 97.0%의 인식결과를 보여 k-NN 분류방법에 비해 1.7%의 성능향상을 보였다. 따라서 제안된 방법의 경우 다른 분류기법에 비해 우수한 성능을 보임을 확인할 수 있었다.

참고문헌

- [1] S. Wu and 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 and M. Fenger, "Current signature analysis to detect induction motor faults," *IEEE Ind. Applicat. Magazine*, pp. 26-34, July/August 2001.
- [3] M. Nejjari and 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. Toliat, "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, Issue 5, pp. 1092-1099, 2000.
- [7] Z. Zhang, Z. Ren, and W. Huang, "A Novel Detection Method of Motor Broken Rotor Bars Based on Wavelet Ridge," *IEEE Trans. on Energy Conversion*, vol. 18, no. 3, September, 2003.
- [8] Z. Ye, B. Wu, and A. Sadeghian, "Current Signature Analysis of Induction Motor Mechanical Faults by Wavelet Packet Decomposition," *IEEE Trans. on Industrial Electronics*, vol. 50, no. 6, December, 2003.
- [9] S. Seker and E. Ayaz, "Feature extraction related to bearing damage in electric motors by wavelet analysis," *Journal of the Franklin Institute*, 2003.
- [10] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*, JOHN WILEY&SONS, Second Edition, 2002.
- [11] V. N. Vapnik, *The Nature of Statistical Learning Theory*, New York. Springer, 1999.
- [12] L. V. Ganyun, H. Cheng, H. Zhai, and L. Dong, "Fault diagnosis of power transformer based on multi-layer SVM classifier," *Electrical Power Systems Research*, vol. 75, pp. 9-15. 2005.
- [13] A. Widodo, B.-S. Yang, and T. Han, "Combination of independent component analysis and support vector machines for intelligent faults diagnosis of induction motors," *Expert Systems with Applications*, In Press, Corrected Proof, Available online 4, Jan. 2006.
- [14] Q. Hu, Z. He, Z. Zhang, and Y. Zi, "Fault diagnosis of rotating machinery based on improved wavelet package transform and SVMs ensemble," *Mechanical Systems and*

Signal Processing, 2006.

- [15] G. R. Bossio, C. H. De Angelo, G. O. Garcia, J. A. Solsona, and M. I. Valla, "Effects of rotor bar and end-ring faults over the signals of a position estimation strategy for induction motors," *IEEE Trans. Industry*

Applications, vol. 41, no. 4, pp. 1005-1011, 2005.

- [16] C.-Chang and C.-J. Lin, (2001), LIBSVM a library for support vector machines, Software available: <http://www.csie.ntu.edu.tw/~cjlin/libsvm>



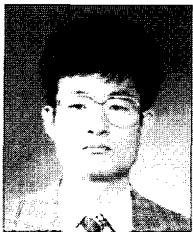
이 대 종

1995년 충북대 전기공학과 졸업. 1997년 동 대학원 석사. 2002년 동 대학원 박사. 2006년~현재 충북대학교 충북정보기술사업단 초빙조교수. 관심분야는 패턴인식, 지능시스템, 데이터마이닝, 생체인식 및 응용 모델링.



송 창 규

1995년 충북대 전기공학과 졸업. 1997년 동 대학원 석사. 2006년 동 대학원 박사. 2006년~현재 충북대학교 충북정보기술사업단 Postdoc. 관심분야는 영상처리, 영상압축, 패턴인식, 퍼지 및 지능시스템.



이 재 경

1980년 서울대 기계공학과 졸업. 1982년 한국과학기술원 기계공학과 대학원 석사. 1996년 동 대학원 박사. 1997년~현재 충주대학교 정보제어공학과 교수. 관심분야는 이동로봇, 지능시스템, 컴퓨터 비전.



전 명 근

1987년 부산대 전자공학과 졸업. 1989년 한국과학기술원 전기및전자공학과 대학원 석사. 1993년 동 대학원 박사. 1996년~현재 충북대학교 전기전자컴퓨터공학부 교수. 관심분야는 Biometrics, 패턴인식, 지능시스템, 데이터마이닝.