

클러스터링과 방사기저함수 네트워크를 이용한 실시간 유도전동기 고장진단

(Real-time Fault Diagnosis of Induction Motor Using Clustering and Radial Basis Function)

박장환* · 이대종 · 전명근

(Jang-Hwan Park · Dae-Jong Lee · Myung-Geun Chun)

요 약

본 논문에서는 3상 유도전동기의 고장진단을 수행하기 위해 패턴인식에 기반을 둔 진단 알고리즘을 제안한다. 실험 장치는 유도전동기 구동의 기계적 모듈과 고장신호를 구하기 위한 데이터 획득 모듈로 구성하였다. 진단 절차를 위한 첫 번째 단계로서 전처리 과정은 획득한 전류를 단순화하고 정규화 하는 것을 수행한다. 데이터의 단순화 과정은 3상전류를 Concordia 벡터의 크기로 변환하는 것을 적용한다. 다음으로 특징 추출 단계를 커널 주성분 분석과 선형판별분석으로 수행하며, 마지막으로, 분류기는 방사기저함수 네트워크를 사용한다. 다양한 부하에 대하여 몇몇의 전기적 고장과 기계적 고장 하에서 획득한 데이터를 이용하여 제안된 방법의 타당성을 검증한다.

Abstract

For the fault diagnosis of three-phase induction motors, we construct a experimental unit and then develop a diagnosis algorithm based on pattern recognition. The experimental unit consists of machinery module for induction motor drive and data acquisition module to obtain the fault signal. As the first step for diagnosis procedure, preprocessing is performed to make the acquired current simplified and normalized. To simplify the data, three-phase current is transformed into the magnitude of Concordia vector. As the next step, feature extraction is performed by kernel principal component analysis(KPCA) and linear discriminant analysis(LDA). Finally, we used the classifier based on radial basis function(RBF) network. To show the effectiveness, the proposed diagnostic system has been intensively tested with the various data acquired under different electrical and mechanical faults with varying load.

Key Words : Induction motor, Fault diagnosis, Kernel PCA, LDA, RBF network

* 주 저 자 : 특허청 전기전자심사국 특허심사관
Tel : 042-481-8463, Fax : 042-472-3551

E-mail : parkjh@kipo.go.kr

접수일자 : 2006년 3월 21일

1차심사 : 2006년 3월 28일

심사완료 : 2006년 4월 12일

1. 서 론

산업 현장에 널리 사용하고 있는 유도전동기들의 예기치 않은 고장은 전체 또는 일부 프로세스의 마

클러스터링과 방사기저함수 네트워크를 이용한 실시간 유도전동기 고장진단

비로 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.

기기의 고장진단의 방법은 모델기반 기법[1]과 지식기반 기법[2-7]이 주류를 이룬다. 모델기반 기법들은 만약 기기를 포함하는 프로세스의 정확한 모델을 구할 수 있다면 매우 뛰어난 진단 시스템을 구축할 수 있다. 그러나, 일반적으로 비선형성(nonlinearity), 섭동(perturbation), 외란(disturbance) 등을 포함하는 전체 시스템의 정확한 모델을 구하기는 쉽지 않다. 그런 까닭에 최근에는 모델의 지식이 요구되지 않는 지식기반 기법을 적용한 많은 연구결과들과 적용 예들을 발표되고 있다. 지식기반기법으로는 전문가 시스템[2], 인공지능 및 통계적 방법[3] 등이 있다. 전문가 시스템은 실용적으로 적용하기 위해서 프로세스에 반영수정(mirror modification)이 필요하고 규칙과 추론계도(reasoning tree)를 세울 수 있는 전문가가 존재해야 한다. 반면에 인공지능 및 통계적 방법들은 모델링을 필요로 하지 않을 뿐만 아니라 전문지식이 필요 없으므로, 보다 폭넓은 적용성과 편리함을 가져다 준다. 이 방법은 정상과 고장조건의 초기 훈련 데이터에 의존성이 큼에도 불구하고, 근래에 적당한 데이터를 얻을 수 있는 시뮬레이션 도구 및 연산 시스템의 발달로 비약적인 발전을 거듭하고 있다.

일반적으로 유도전동기의 온라인 고장진단은 진동신호 모니터링[4]과 MCSA(motor current signal analysis)[5-7]에 의해서 이루어진다. 과거에는 진동모니터링에 기반을 둔 연구가 많이 이루어져 있지만, 산업 전반에 사용되고 있는 중소형 유도전동기에 이러한 고장진단 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 이용하는 경우, 온라인 고장진단 과정이 간단하고, 절연상태를 제외한 대부분의 전기적·기계적 고장상태를 진단할 수 있으므로, 최근 이들에 관한 연구가 활발

히 진행되고 있다.

MCSA에 신호검출과 인공지능 및 통계적 방법을 이용하여 유도전동기의 고장진단을 수행한 문헌들을 보면, Fenger[5]는 유도전동기의 다양한 고장들에 대한 스펙트럼 분석에 기반을 둔 MCSA의 성능을 분석한 결과를 보여 주었다. Nejjari[6]와 Zidani[7]는 각각 인공신경망과 퍼지논리에 기반을 두고 진단 알고리즘을 설계하였으며, 시간영역에서 단지 입력전류의 Concordia 벡터들을 가지고 고장진단을 수행하는 방법을 제시하였다.

본 논문은 상기한 시간영역 상에서 MCSA와 통계적 패턴인식 기법을 이용하여 유도전동기의 온라인 고장진단 시스템을 구현하는데 목적을 둔다. 고장진단 수행에 앞서 먼저 진단을 위한 구동 시스템을 제작한다. 이로부터 고장진단의 수행은 먼저, 3상 측정신호를 Concordia 벡터를 이용하여 2차원 신호로 변환한 후, 진단신호로 사용될 1차원 크기(magnitude) 값을 산출한다. 다음으로, 다양한 부하상황과 주위환경에서 검출한 데이터 샘플들을 FCM(fuzzy c-means)을 이용하여 적절한 개수의 클러스터 중심 벡터들을 구한다. 이 벡터들로부터 KPCA(kernel principal component analysis)와 성능개선을 위해 추가한 LDA(linear discriminant analysis)를 적용하여 특징 추출을 한다. 최종적으로 최적의 성능을 갖는 분류 또는 진단을 수행하기 위해 RBF 네트워크를 이용한다.

본문의 내용은 2장에서는 진단신호의 형성과정을 보였고, 3장에서는 특징추출에 필요한 알고리즘을 정리하였다. 4장에서는 실험 장치와 제안한 진단 알고리즘을 이용한 온라인 고장진단 시스템의 우위성을 보여준다. 5장은 결론이다.

2. 유도전동기 전류신호 해석

대부분의 유도전동기의 고장은 순간적으로 발생하지 않고, 오랜 사용에 따른 노화나 부적절한 부하환경 등에 의해 서서히 고장이 발생한다. 이러한 고장을 온라인으로 검출하기 위해 모든 신호를 검출할 필요가 없으므로, 우리는 t_s , 초마다 영점교차점을 이용하여 한 주기의 전류 샘플을 검출한 후에, 정량적

인 해석방법을 이용한 진단 시스템에 적용하게 될 것이다. 그림 1의 (a)는 이상적으로 t_s 초마다 검출되는 1-주기 샘플의 전류신호를 보여준다.

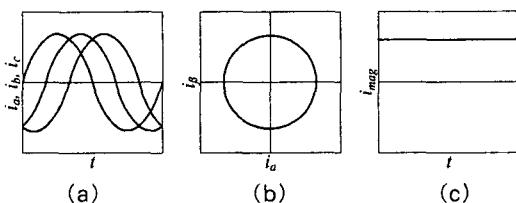


그림 1. 이상적인 조건에서 전류 패턴들

Fig. 1. The current patterns on ideal condition

3상 유도 전동기의 공급 전류는 Concordia 벡터에 기반을 두고 2-차원으로 표현을 할 수 있다[7]. 식 (4)와 같이 전류 Concordia 벡터 성분들(i_a, i_b)은 3상 기본 전류들(i_a, i_b, i_c)의 합수이며,

$$i_a = \sqrt{\frac{2}{3}} i_a - \frac{1}{\sqrt{6}} i_b - \frac{1}{\sqrt{6}} i_c \quad (1)$$

$$i_b = \frac{1}{\sqrt{2}} i_b - \frac{1}{\sqrt{2}} i_c$$

이상적인 조건에서 3상 전류는 다음의 Concordia 벡터 성분들을 가진다.

$$i_a = \frac{\sqrt{6}}{2} I \cdot \sin \omega_s t \quad (2)$$

$$i_b = \frac{\sqrt{6}}{2} I \cdot \sin \left(\omega_s t - \frac{\pi}{2} \right)$$

여기서 I 와 ω_s 는 각각 최대 전류와 각속도를 표시한다. 그림 1 (b)는 Concordia 벡터의 경로를 보여주며, 원점에 중심을 두는 원의 형상을 갖는다.

고장진단과정의 계산 시간을 고려하면, 일반적으로 2-차원 데이터 집합보다 1차원의 데이터 샘플들이 보다 적은 계산 시간을 가지고 진단을 수행할 수 있을 것이다. 차원축소를 위하여 2-차원의 Concordia 벡터들은 식 (3) 같이 위상성분을 무시한 1차원 크기(magnitude)들의 집합으로 변환을 한다.

$$i_{mag} = i_a^2 + i_b^2 \quad (3)$$

그림 1 (c)는 식 (3)에 의해 변환된 전류 파형을 보여준다. 이 그림에서와 같이 이상적인 상황에서는 전류의 파형이 상수 값을 갖는다. 만일 3상 유도전동기에 비정상적인 상황이 발생하였을 때, 이 파형은 예곡이 발생할 것이며, 우리는 그 비정상적인 파형의 변화를 다음 장에 제안한 진단 기법에 의해 고장의 한 부류로 추론하게 될 것이다.

3. 진단 알고리즘

유도전동기의 고장진단을 위하여 제안한 진단기법의 기본 구성도는 그림 2에서 보여준다. 그것은 전처리 과정, 특징추출과 분류 부분으로 구성된다.

제안한 고장진단과정을 보면, 먼저, 훈련을 위해 반복 실험한 결과들은 동일한 정상 및 고장 환경에서 습득한 데이터들일 지라도 입력전원, 부하 등의 상태에 따라 습득 데이터들은 많은 차이를 보인다. 이러한 데이터들로부터 특징추출을 하기 위하여 우리의 연구에서는 FCM[8]을 이용하여 필요한 개수의 훈련 데이터를 각각의 클러스터 중심점으로 선택한다. 즉 클래스 내부에서 클러스터링에 의해 원하는 개수의 중심점을 잡아주고 이들을 소위 부-클래스로 두어 특징추출은 독립적인 클래스로 놓고 진단 과정에서 각각의 부-클래스들을 클래스로 묶어 진단을 수행할 것이다.

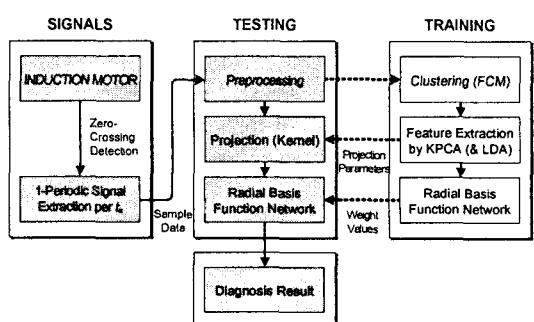


그림 2. 제안한 진단 알고리즘의 구성도

Fig. 2. The configuration for the proposed diagnosis algorithm.

특징 추출은 KPCA[8]와 LDA[8]를 이용한다. KPCA는 PCA가 공분산 행렬 대신에 내적 행렬 상

클러스터링과 방사기저함수 네트워크를 이용한 실시간 유도전동기 고장진단

에서 수행될 수 있다는 잘 알려진 사실로부터 다음과 같이 유도된다[9]. 샘플들 $(x_i \in R^M)_{i=1}^N$ 이 전처리 과정을 거친 전동기의 전류 데이터의 집합을 표시한다고 하자. KPCA는 먼저 함수 $\Phi: R^M \rightarrow F$ 에 의해 특징공간 F 로 데이터를 사상한 다음 사상된 데이터를 가지고 표준 PCA를 수행한다. $X = [\Phi(x_1) \cdots \Phi(x_N)]$ 에 의해 데이터 행렬 X 를 정의하면, F 에서의 공분산 행렬 C 는 다음과 같다.

$$C = \frac{1}{N} \sum_i^N \Phi(x_i) \Phi(x_i)^T = \frac{1}{N} X X^T \quad (4)$$

사상된 데이터가 $1/N \cdot \sum_i^N \Phi(x_i) = 0$ 에서 중심을 갖는다고 가정하면, 식 (5)의 고유값 문제에 의하여 C 의 고유값과 고유벡터들을 찾을 수 있다.

$$\lambda u = Ku \quad (5)$$

여기서 행렬 K 는 $K = 1/N \cdot X^T X$ 로 정의된 $N \times N$ 내적 행렬이며, 성분은 다음과 같다.

$$K_{ij} = \frac{1}{N} \Phi(x_i) \cdot \Phi(x_j) = \frac{1}{N} k(x_i, x_j) \quad (6)$$

행렬 $K(P \leq N, P \leq M)$ 의 영이 아닌 고유값과 고유벡터가 각각 $\lambda_1 \geq \cdots \geq \lambda_k, u_1, \dots, u_k$ 이라 하면, C 는 동일한 고유값들을 가지며, $C: v^k = \alpha^k X u^k$ (여기서 α^k 는 정규화 상수이다)의 영이 아닌 고유벡터들 $\{v^k\}$ 과 K 의 영이 아닌 고유벡터들 $\{u^k\}$ 사이는 일대일 대응관계가 있다. 만약 고유벡터들이 단위길이를 갖는다면, $\alpha^k = 1/\sqrt{\lambda_k N}$ 이며, $\alpha^k = 1$ 이기 위해 $\|v^k\| = 1/\sqrt{\lambda_k N}$ 을 가정한다.

전처리 과정을 거친 시험 데이터 샘플 x 에 대해, 그것의 k -번째 주성분 y_k 는 다음의 커널 함수를 사용하여 계산할 수 있다.

$$y_k = v^k \cdot \Phi(x) = \sum_{i=1}^N u_i^k k(x, x_i) \quad (7)$$

이때에 식 (8)의 사영(projection) 연산자 P_H 를 사용함으로써 x 에 대한 Φ 의 상(image)을 그것의

사영들로부터 F 에서 첫 번째 $H(\leq P)$ 주성분들 위로 재구성할 수 있다.

$$P_H \Phi(x) = \sum_{h=1}^H y_h v^h \quad (8)$$

통상적으로 사용하는 커널은 식 (9)와 같은 다항식, 가우시안과 시그모이드 커널 등이 있다.

$$k(x, y) = (x, y)^d \quad (\text{polynomial}) \quad (9a)$$

$$k(x, y) = \exp\left(-\frac{\|x-y\|}{2\sigma^2}\right) \quad (\text{Gaussian}) \quad (9b)$$

$$k(x, y) = \tanh(x, y) + \Theta \quad (\text{sigmoid}) \quad (9c)$$

이상의 KPCA는 입력 데이터 샘플들 간에 고차원 상관관계를 가진 특징들을 얻을 수 있게 하여, 데이터 샘플의 커널 사영은 입력 데이터의 비선형 공간적인 구조를 감소시킨다. 즉 입력 데이터 내부에 고유의 비선형 구조는 주성분 부분공간에서 비교적 좋은 결과들을 가져다 줄 수 있다.

고장진단 시스템의 판별능력을 증가시키기 위해 이 논문에서는 특징추출을 위해 KPCA에 LDA를 추가로 사용한다. 간단하게 LDA는 샘플들의 클래스내 분산에 대한 클래스간 분산의 비를 최대화하도록 하는 사영벡터(projection vector)를 구하여 샘플들의 분포를 판별성이 크게 해주는지 사용될 수 있다[10].

최종적으로 추출된 특징 값들을 분류(classification)하기 위한 기법으로, 보다 향상된 성능을 얻기 위하여 RBF 네트워크[8]를 사용하며, 그것은 네트워크가 간결하고 개인화의 장점을 갖기 때문이다.

이상의 진단 알고리즘을 온라인 고장진단과정에 적용하기 위하여 먼저 훈련을 통하여 KPCA와 LDA의 사영 파라미터들과 RBF 네트워크의 가중치 값을 구한다. 실제 온라인 고장진단 검사 과정에서는 이 값을 참조하여 그림 2의 중앙 부분과 같은 단계로 수행한다.

4. 실험 및 결과

4.1 고장시스템의 구성

유도전동기 고장진단을 위해 설치한 실험장치의 주요부분은 유도전동기 구동부, 데이터 습득부와 고장진단부로 구성하였다. 세부적으로 유도전동기 구동부분은 전동기구동부, 전동기, 안전장치, 다양한 전압표시장치, 전류센서와 진동센서의 구동회로, 그리고 전기적 브레이크 기능을 갖는 부하 시스템을 갖는다. 데이터 습득부분에서는 3상 전류를 PC로 전송하기 위해 NI사의 PCI-6251 DAQ 보드를 사용하여 10[kHz]의 샘플링 데이터를 검출한다. 고장진단 부분은 PC 상에서 LabVIEW 7.1 프로그램을 이용하여 온라인으로 진단결과를 구한다.

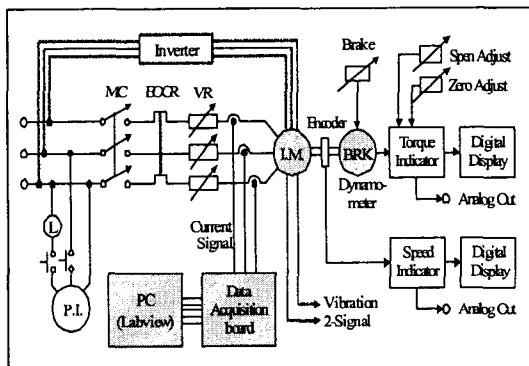


그림 3. 진단 시스템의 블록선도
Fig. 3. Block diagram of a diagnosis system

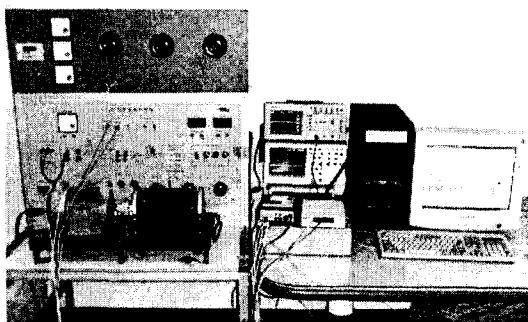


그림 4. 실험장치
Fig. 4. A laboratory equipment

그림 3은 실험에 사용한 진단 시스템의 블록선도를 나타내며, 그림 4는 데이터 취득 및 진단을 위한 실험장치를 나타냈다. 또한 표 1에서는 본 실험에서 사용된 진단시스템의 기본적 구성요소들의 사양을 나타냈다.

표 1. 진단 시스템의 사양

Table 1. The specification of diagnostic system

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

4.2 전기적 고장과 기계적 고장

전기적 고장과 기계적 고장 데이터를 취득하여 제안한 온라인 고장진단 기법을 타당성을 검증하고자 한다. 먼저 3상 유도전동기의 전기적 고장은 3상들 간에 불평형(unbalance)을 갖는 고장을 사용한다. 이것은 실제 불평형 상에 관계한 전기적 고장들과 같이 전자기 속(flux)을 달리지게 하므로, 고정자 코어에 작용하는 역기전력을 변하게 하며, 입력전류 값을 변화시킨다. 이와 같은 전기적 고장을 구현하기 위해, 그림 3에서 보여주는 것과 같이 전동기 입력 단에 가변저항기를 설치한다. 표 2의 상단부분은 본 연구에서 고려한 입력 단의 저항 값 변화에 따른 3가지 전기적 고장을 나타낸다.

유도 전동기의 기계적 고장은 많은 응용분야에서 전기적 고장보다 일반적으로 발생하는 고장이다. 기계적 고장들의 주요한 것들로, 고정자(stator) 고장, 회전자 불균형(rotor imbalance), 에어캡 불규칙(ari-gap irregularities), 축의 휀(bend shaft), 불일치한 정열(misalignments), 베어링 손상, 기어박스 손상 및 기계적 이완(looseness) 등이 있다. 이 논문에서는 이러한 고장들을 대신하여 전동기의 고정용 나사의 조작에 의한 기계적인 이완들에 관련하여 진

클러스터링과 방사기저암수 네트워크를 이용한 실시간 유도전동기 고장진단

단을 수행한다. 3상 전류들이 대칭인 전동기를 직각의 모서리 방향에서 고정시키는 4개의 나사가 단단하게 고정되었을 때 유도전동기는 정상 상태라 한다. 고장상태는 3가지 이원등급, 즉, 앞쪽 나사 2개, 뒷쪽 나사 2개, 그리고 모든 나사 4개에 의한 이원 등급을 가지며 이에 따라 변화한 전류신호를 습득하여 고장 진단에 사용한다. 표 2의 하단부분은 이러한 3가지 등급의 기계적 고장을 나타낸다.

표 2. 고장조건
Table 2. The kind of fault mode

Fault	Condition	Load
Health	No faulty condition	
Electrical Faults	unbalance for a phase(5[Ω])	1. No load
	unbalance for a phase(10[Ω])	2. 0.04[kg·m]
	unbalance for a phase(15[Ω])	3. 0.08[kg·m]
Mechanical Faults	Looseness of two left screws	4. 0.12[kg·m]
	Looseness of two right screws	5. 0.16[kg·m]
	Looseness of all screws	

4.3 온라인 고장진단 결과

온라인 고장진단은 LabVIEW 상에서 영점교차점을 이용하여 1초마다 습득하는 1주기의 전류신호에 대하여 고장진단을 수행한다. 먼저 LabVIEW의 프로그램을 요약하면, DAQ 보드로부터 들어온 입력데이터들을 주어진 일정 시간마다(1초) 한 주기($10[\text{kHz}]$ 에서 167개) 샘플을 검출한다. 다음으로 MATLAB script을 이용하여 MATLAB 프로그램 상에서 설정된 진단 과정을 따라 고장진단을 수행하며 샘플데이터와 진단결과를 저장한 후에 진단결과를 다시 LabVIEW 상으로 보내준다.

그림 5는 실제 고장진단을 위한 LabVIEW 프로그램을 보여준다. 그림에서 MATLAB Script 부분에 들어가는 계수 값들은 오프라인 상에서 제한한 알고리즘을 토대로 $10[\text{kHz}]$ 의 전류 데이터들에 대해, 중심점의 개수 $N = 10$ 의 FCM, 다항식 커널을 적용한 커널 PCA 함수와 LDA의 사영행렬 값, RBF 네트워크의 계수들을 적용하여 온라인상에서 고장진단을 수행한다. 또한 매 주어진 시간(여기서는 1초)마다

진단 결과를 Matlab의 워크스페이스에서 업데이트를 해준다. 이것은 온라인 진단 후에 유도전동기의 상태 경향(status trend)을 보여준다.

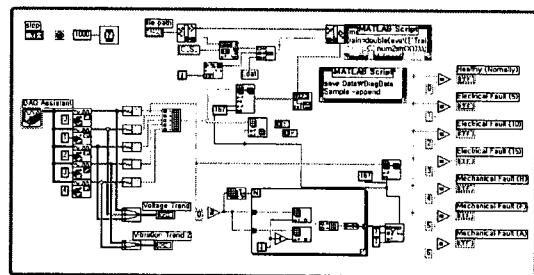


그림 5. LabVIEW 프로그램
Fig. 5. LabVIEW program

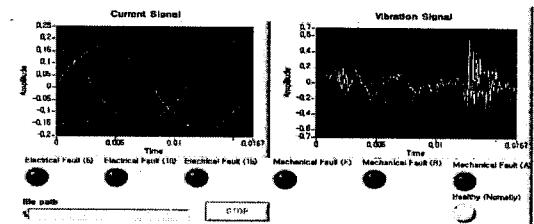


그림 6. 온라인 고장진단의 일례: 정상
Fig. 6. A example of on-line fault diagnosis: health

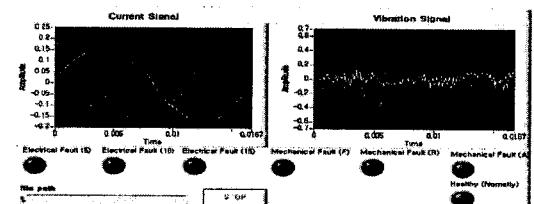


그림 7. 온라인 고장진단의 일례 : 기계적 고장
Fig. 7. A example of on-line fault diagnosis: mechanical fault

그림 6 및 7은 진단결과의 일례를 보여주며, 그림 6은 정상상태일 때 진단결과이고, 그림 7은 모든 고장나사를 느슨하게 한 기계적 고장의 진단결과를 각각 나타낸다. 이 그림에서 상단 좌측의 그래프는 1초마다 검출되는 1주기의 3상 전류신호이고, 상단 우측 그래프는 본 연구에서 이용하지 않았으나 검출한 두 가지의 진동신호를 보여준다. 하단의 원형 표시장치는 각각 정상상태(H)와 3가지 전기적 고장

(E1~E3)과 3가지 기계적 고장(M1~M3)의 진단결과를 표시한다.

표 3에서는 온라인 고장진단을 수행하였을 때에 평균 진단결과를 나타냈다. 일반적으로 PCA와 LDA를 이용하여 패턴을 분류한 기존 연구에서는 최종 진단을 위해 Hamming 거리척도 (L1) 또는 Euclidean 거리척도 (L2) 방법을 사용하므로 본 연구에서도 위에 열거한 거리척도 기법과 본 논문에서 제안된 RBF 기반 분류기법과 비교실험을 하였다. 실험결과, 표 3에서 보는 바와 같이 제안된 RBF 네트워크 기반 분류기를 사용한 경우 Hamming 거리척도 (L1)나 Euclidean 거리척도 (L2)에 의한 분류방법보다 향상된 진단 성능을 보임을 알 수 있다. 또한, 본 논문에서 적용된 KPCA와 LDA를 이용한 특징추출 방법이 기존의 PCA와 LDA를 적용한 경우보다 우수한 결과를 보임을 알 수 있다.

표 3. 성능지수
Table 3. The performance rate

Method	H	E1	E2	E3	M1	M2	E1	Tot.
KPCA+LDA,RBFN	90.7	96.1	100	100	91.2	93.9	93.7	95.1
KPCA+LDA, L1	90.1	95.9	100	96.3	90.7	94.5	94.5	94.6
KPCA+LDA, L2	88.4	96.1	100	96.0	91.7	93.9	93.7	94.0
PCA+LDA, L1	78.1	94.3	100	100	80.2	84.2	83.2	88.6
LDA, L1	63.8	96.3	100	98.1	74.4	86.5	85.5	86.3

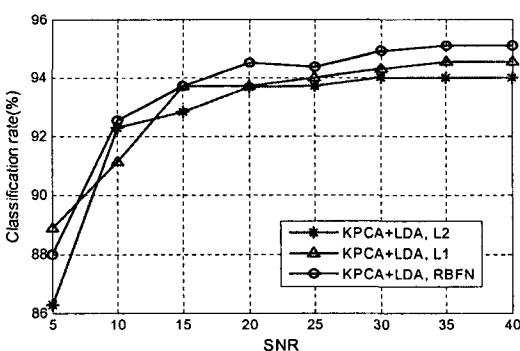


그림 8. SNR에 따른 성능비
Fig. 8. The performance rate by SNR

표 3에 나타낸 실험결과를 분석한 결과, 특징추출기법으로 기존의 PCA보다 커널 PCA를 이용하고

LDA를 추가함으로써, 대략 3[%] 이상의 성능 향상을 가져왔으며, Hamming 거리척도 (L1)에 의한 분류 방법보다 RBF 네트워크를 사용하여 0.5[%] 정도의 향상된 인식결과를 보여주었다. 최종적으로 본 연구에서 구성한 시스템의 고장진단 기법은 95.1[%] 정도의 성능을 보여 주었다.

그림 8은 SNR(signal to noise ratio)이 100~0으로 변화시킬 때에 성능지표의 변화이며, 그림에서 볼 수 있듯이 RBF 네트워크에 의한 진단 기법은 외란에 대해서도 강인한 성능을 보여줄 수 있다.

5. 결 론

본 논문에서는 FCM 클러스터링 기법, 주성분분석기법과 선형판별분석기법을 이용하여 특징추출을 하고, 방사기저함수 네트워크를 이용하여 부하가 변동하는 유도전동기의 고장진단을 온라인으로 수행하는 알고리즘을 제안하였다.

먼저 기존에 구성된 진단 시스템을 이용하여 오프라인 상에서 실험 데이터를 추출한 후에 고장진단 특성 실험을 하였다. 진단 기법으로 PCA와 LDA의 융합을 통한 진단 알고리즘과 클러스터링 기법과 RBF 네트워크를 이용한 고장진단 알고리즘을 개발하였다. 이를 제안된 방법의 타당성을 보이기 위한 시뮬레이션 결과를 비교 분석하였으며 결과적으로 온라인 진단 기법 시스템을 구축하였다. 온라인 고장진단은 실험을 위해 제작한 고장진단 시스템과 데이터 습득 보드, PC를 가지고 수행하였다. 진단 알고리즘은 최종적으로 클러스터링과 커널 PCA, LDA에 의해 특징추출과 RBF 네트워크에 의한 진단 기법을 사용하였으며, 실제 시스템의 진단은 LabVIEW 프로그램 상에서 MATLAB script에 포함되어 있는 제안한 알고리즘을 이용하여 진단 결과를 얻어냈다.

진단 결과는 먼저 특징추출은 PCA보다 커널 PCA를 이용하고 LDA를 추가함으로써, 대략 3[%] 이상의 성능 향상을 가져왔으며, 최소거리에 의한 분류 방법보다 RBF 네트워크를 사용하여 0.5[%] 정도의 향상된 인식결과를 보여주었다. 최종적으로 본 연구에서 구성한 시스템의 고장진단 기법은 95.1[%]

클러스터링과 방사기저함수 네트워크를 이용한 실시간 유도전동기 고장진단

정도의 성능을 보여주었다. 이것이 100[%]의 결과를 보여주지 않는 것은 부하의 변동과 주변 상황 및 외란과 같은 데이터의 섭동에 의해 구분하기 어려운 샘플들이 형성되었기 때문일 것이다.

본 연구는 산업자원부의 지원에 의하여 기초전력공동 연구소(R-2003-B-285) 주관으로 수행된 과제임.

References

- [1] S. B. Dolines et al., "A curve interpretation and diagnosis technique for industrial process," *IEEE Trans. Ind. Applicat.*, vol. 28, no. 1, pp. 261-267, January/February 1992.
- [2] J. Sottile et al., "An overview of fault monitoring and diagnosis in mining equipment," *IEEE Trans. Ind. Applicat.*, vol. 30, no. 5, pp. 1326-1332, September/October 1994.
- [3] D. Diall et al., "Fault detection and diagnosis in an induction machine drive: a pattern recognition approach based on Concordia stator mean current vector," *IEMDC'03*, vol. 3, pp. 1448-1453, June 2003.
- [4] 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, February 2004.
- [5] W. T. Thomson, M. Fenger, "Current signature analysis to detect induction motor faults," *IEEE Ind. Applicat. Magazine*, pp. 26-34, July/August 2001.
- [6] 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, May/June 2000.
- [7] 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.

- [8] Bezdec, J.C., *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.
- [9] B. Scholkopf, A. Smola, "Nonlinear component analysis as a kernel eigenvalue problem," *Neural Computation*, vol. 10, pp 1299-1319, 1998.
- [10] Richard O. Duda et al, *Pattern Classification*, John Wiley & Sons Inc, 2nd Ed., 2002.

◇ 저자소개 ◇

박장환(朴長煥)

1967년 9월 5일생. 1991년 충북대학교 전기공학과 졸업. 1993년 충북대학교 대학원 전기공학과 졸업(석사). 1999년 동대학원 졸업(박사). 2001~2005년 충주대학교 정보제어공학과 계약교수(BK21), 2005년~현재 특허청 전기전자심사국 특허심사관.

이대중(李大鍾)

1969년 2월 25일생. 1995년 충북대학교 전기공학과 졸업. 1997년 충북대학교 전기공학과 졸업(석사). 2002년 충북대학교 전기공학과 졸업(박사). 2003~2004년 컴퓨터정보통신연구소 연구원. 2004~2005년 Jointed university of Alberta as a postdoctoral.

전명근(全命根)

1964년 7월 17일생. 1987년 부산대학교 전자공학과 졸업. 1989년 한국과학기술원 전기 및 전자공학과 졸업(석사). 1993년 한국과학기술원 전기 및 전자공학과 졸업(박사). 1993~1996년 삼성전자 자동화연구소 선임연구원. 2000~2001년 University of Alberta 방문교수. 1996년~현재 충북대학교 전기전자컴퓨터공학부 교수.