

# PCA와 LDA에 기반을 둔 융합알고리즘에 의한 유도전동기의 고장진단

(Fault Diagnosis of Induction Motor by Fusion Algorithm based on PCA and LDA)

전병석\* · 이대중 · 이상혁 · 유정웅 · 전명근

(Byeong-Seok Jeon · Dae-Jong Lee · Sang-Hyuk Lee · Jeong-Woong Ryu · Myung-Geun Chun)

## 요 약

본 논문에서는 산업전반에 걸쳐 널리 사용되는 유도전동기의 고장상태를 검출하기 위해 PCA와 LDA에 기반을 둔 융합모델을 이용한 진단 알고리즘을 제안하고자 한다. 실험에 의해 측정된 전류값을 PCA와 LDA를 이용하여 특징벡터를 산출한 후 검증데이터를 이용하여 각각의 매칭값을 산출한다. 진단단계는 PCA와 LDA에 의해 각각 산출된 두 개의 매칭값을 확률모델에 의해 융합한 후 최종적으로 검증하는 구조로 되어있다. 제안된 진단 알고리즘의 경우 PCA와 LDA의 장점만을 부각시킴으로써 노이즈가 존재하는 환경하에서도 우수한 성능을 보인다. 제안된 방법의 타당성을 보이기 위해 노이즈가 있는 다양한 조건하에서 실험한 결과 기존의 PCA 또는 LDA만을 이용한 경우보다 우수한 결과를 나타냈다.

## Abstract

In this paper, we propose a diagnosis algorithm using fusion model based on PCA and LDA to detect fault states of the induction motor that is applied to various industrial fields. After yielding a feature vector from the current value measured by an experiment using PCA and LDA, training data is made to produce each matching value. In a diagnostic step, two matching values yielded by PCA and LDA are fused by probability model and finally verified. Since the proposed diagnosis algorithm takes only merits of PCA and LDA, it shows excellent results under noisy environments. The simulation results to verify the usability of the proposed algorithm showed better performance than the case just using conventional PCA or LDA.

Key Words : induction motor, fault diagnosis, fusion algorithm, PCA, LDA

## 1. 서 론

산업발달과 더불어 산업현장에서 전동기의 수요는 매년 증가하고 있다. 그 중에서도 유도전동기는 구조적으로 간단하고 견고할 뿐만 아니라 비용면에서도 저렴하기 때문에 산업용, 가정용 전동기로서

\* 주저자 : 충북대학교 전기공학과 박사과정  
Tel : 043-261-2419, Fax : 043-263-2419  
E-mail : koamma88@chungbuk.ac.kr  
접수일자 : 2005년 1월 21일  
1차심사 : 2005년 1월 24일  
심사완료 : 2005년 2월 7일

가장 널리 사용되고 있다. 이러한 유도전동기가 가동 중 갑작스런 고장에 의해 구동기능을 상실할 경우 시스템 전체의 마비로 이어져 치명적인 경제적 손실을 초래하게 된다. 따라서 전동기의 고장상태를 미리 예측하여 사고를 미연에 방지할 수 있는 유지·보수의 측면이 강조되고 있으며, 전동기의 고장 시 적절한 판단은 고장 또는 수명 예측과 더불어 중요한 부분으로 인식되고 있다[1].

유도전동기의 고장의 종류는 크게 절연불량에 의한 고장과 전기적·기계적 결합에 의한 고장으로 분류된다. 이 중에서도 전동기 시스템에 있어서는 절연불량에 의한 고장보다는 대부분 전기적·기계적 결합에 의한 고장이 대부분을 차지하고 있다. 전기적·기계적 결합으로는 불평형 전원전압과 공극 불균형에 따른 고정자의 고장, 2차권선 불평형과 축의 휨에 의한 회전자의 고장, 회전자의 파손·크랙, 고정자 적층의 단락, 단락량의 파손·크랙, 공극 불균형에 따른 고정자 및 회전자의 편심, 축과 커플링의 정렬불량, 베어링의 파손 이 있다. IEEE 전동기 신뢰성 그룹에 따르면 유도전동기의 고장 원인 중 베어링과 관련된 고장은 40[%], 고정자와 관련된 고장은 38[%], 회전자와 관련된 고장은 10[%], 기타 12[%]라 하므로 대부분의 고장은 베어링, 고정자, 회전자에 의해 발생한다는 것을 알 수 있다[2~3].

유도전동기의 고장을 진단하기 위해 기존의 연구들에서는 유도전동기의 진동신호를 처리하여 진단 시스템을 구성하는 기계적 방법에 크게 의존해왔다. 진동신호를 고장진단을 위한 정보로 활용하는 경우에 대한 선행 연구가 많이 이루어져 있지만, 진동신호검출을 위해 부착하는 센서의 위치선정 등 진단을 위한 처리기법 이외에도 부가적인 데이터 취득 장치에 의해서 성능이 결정될 수 있다. 이러한 진동감지기법의 문제점으로 인하여 최근에는 전동기의 전류신호를 분석하는 MCSA(motor current signature analysis) 검출기법에 관한 연구가 활발히 진행되고 있다. MCSA 검출방법을 이용할 경우 절연상태를 제외한 고정자 및 회전자의 정적·동적편심 및 베어링의 고장상태를 진단할 수 있다. 또한 온라인 상태에서도 고장진단을 수행할 수 있으므로 현재 널리 사용되고 있는 검출기법이다[4~7].

MCSA 검출방법에 의해 전류신호를 취득한 후 진단을 위해 사용되는 특징벡터 추출기법으로 주성분분석(PCA : principal component analysis)기법과 선형판별분석(LDA : linear discriminant analysis)기법을 제시하였다[11]. 그런데 LDA기법의 경우 노이즈가 없는 상태에서는 제시된 모든 고장상태에 대해 100[%]의 진단율을 나타내지만 노이즈가 심한 경우에는 LDA의 특성이 왜곡되어 급격한 진단을 하려움을 초래한다.

따라서 본 논문에서는 PCA기법과 LDA기법으로 구성된 융합알고리즘을 이용하여 노이즈가 존재하는 환경하에서도 강인한 고장검출을 할 수 있는 유도전동기의 특징추출 및 진단기법을 제안하고자 한다. 여기서 유도전동기의 운전 상태는 정상상태, 회전자봉의 파손상태, 회전자축이 휘어진 상태, 정적편심상태 및 동적편심상태 등 6가지이다. 제안된 진단기법에서는 측정된 전류값을 주기별로 PCA기법과 LDA기법을 이용하여 특징벡터를 계산한 후 검증데이터를 이용하여 각각의 정합값을 산출한다. 최종 진단단계에서는 PCA기법과 LDA기법에 의해 각각 산출된 두 개의 정합값을 확률모델에 의해 융합한 후 최종 검증하는 구조로 되어있다. 제안된 진단 알고리즘의 경우 PCA기법과 LDA기법의 장점만을 부각시킴으로써 노이즈가 존재하는 환경하에서도 우수한 성능을 보이도록 하였다. 제안된 방법의 타당성을 보이기 위해 노이즈가 있는 다양한 조건하에서 실험한 결과 기존의 PCA기법과 LDA기법만을 각각 이용한 경우보다 우수한 성능을 나타냈다.

본 논문의 구성은 다음과 같다. 2장에서는 제안된 융합모델의 구조 및 진단알고리즘에 대하여 설명한다. 3장에서는 다양한 조건하에서 실험을 통해 제안된 방법의 타당성을 검토하고 마지막으로 4장에서 연구결과에 대한 결론을 제시한다.

## 2. 유도전동기의 고장진단 시스템

본 논문에서 제안된 유도전동기의 고장진단 시스템은 그림 1에서 보는 바와 같이 동기화 과정을 수행하는 전처리부, PCA기법에 기반을 둔 고장진단부, LDA기법에 기반을 둔 고장진단부 및 융합모델부로

PCA와 LDA에 기반을 둔 융합알고리즘에 의한 유도전동기의 고장진단

구성되어 있다. 우선 동기화에서는 측정된 전류의 위상이 다를 경우 같은 고장의 데이터들이 다른 결과를 나타내기 때문에 측정된 전류신호의 원점을 0에 가깝게 조정한다. 실제 측정시에는 위상 동조가 맞춰져야 하지만 실험 여건상 위상을 동조시켜 데이터를 획득하는 데는 어려움이 있다. 따라서 샘플링된 데이터의 위상을 맞춰야 하는데 정확한 0의 위상을 맞추기는 어렵지만 0의 근처의 값을 원점으로 하여 전체 데이터의 위상을 동조시킬 수 있다. 이와 같이 비동기된 신호에 의해 생기는 문제점 해결을 위해 원점을 기준으로 동기화 시킨 후 PCA기법 및 LDA기법에 의해 입력전류에 대한 특징벡터를 각각 산출한다.

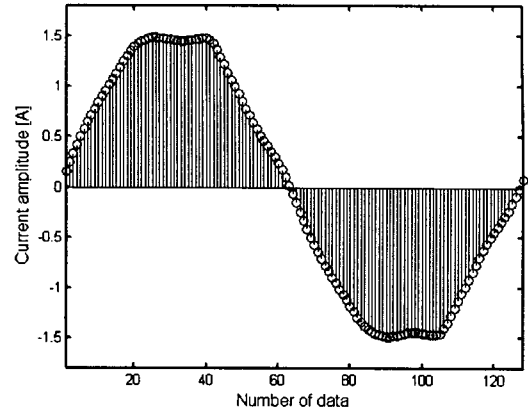


그림 2. 측정된 전류신호  
Fig. 2. A measured current signal

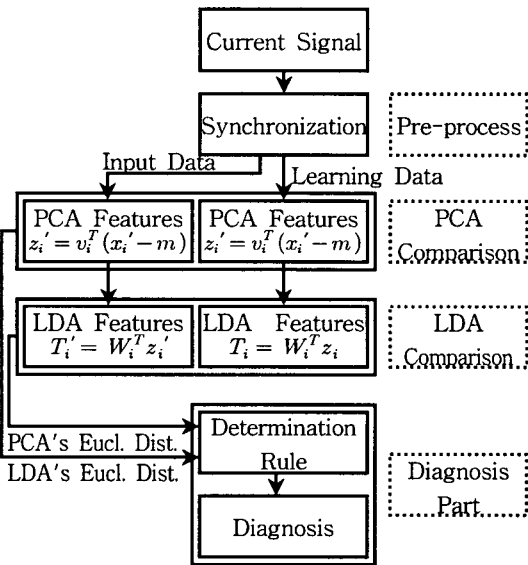


그림 1. 유도전동기의 고장검출 시스템  
Fig. 1. Fault diagnosis system for IM

PCA기법 및 LDA기법에 의한 특징추출 및 비교부에서는 훈련과정에서 미리 계산된 진단 모델별 특징벡터와 입력벡터간의 유클리드 거리를 산출한다. 여기서, 유도전동기의 운전상태는 건전상태, 베어링 고장, 회전자 휨, 회전자바 고장, 정적편심, 동적편심 등 6종류로 구성되어 있다. 최종 진단단계에서는 PCA기법과 LDA기법에 의해 각각 산출된 두 개의 정합값을 확률모델에 의해 융합한 후 최종 검증하는 구조로 되어있다.

PCA기법과 LDA기법에 의한 특징추출 및 비교과정에 대하여 설명하고자 한다. 이와 관련된 내용은 문헌[8~11]에 자세히 기술되어 있다. 우선 PCA기법에 의한 특징추출과정을 단계별로 살펴보면 다음과 같다.

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

$$m = \frac{1}{P} \sum_{i=1}^P x_i \tag{1}$$

[단계 2] 전류신호에 대한 공분산행렬을 구한다.

$$\Omega = \overline{XX^T} \tag{2}$$

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

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

$$\Omega v_j = \lambda v_j \tag{3}$$

[단계 4] 고유벡터  $v_j$ 를 고유값의 크기 순으로 나열한 후 학습신호  $x_i$ 에 대한 특징벡터  $z_i$ 를 구한다. 식 (4)에서 알 수 있는 바와 같이 입력신호에 대한

특징벡터는 공분산에 대한 고유벡터를 이용하여 PCA변환된 공간으로 투영함으로써 얻을 수 있다.

$$z_i = v_i^T(x_i - m) \quad (4)$$

[단계 5] PCA기법에 의해 입력전류(검증데이터)의 특징벡터를 산출한다.

$$z_i' = v_i^T(x_i' - m) \quad (5)$$

여기서  $x_i'$ 은 인식하고자 하는 입력전류를 나타낸다.

[단계 6] 미리 계산된 특징벡터  $z_i$ 와 입력벡터  $z_i'$ 간의 유클리드 거리를 산출한다.

LDA기법은 클래스내의 분산을 나타내는 WCS (within-class scatter)행렬  $S_W$ 와 클래스간 분산을 나타내는 BCS(between-class scatter)행렬  $S_B$ 의 비율이 최대가 되는 행렬을 구하고, 이 행렬을 이용하여 선형변환하는 기법이다. 즉 PCA기법과 같이 투영된 분산을 최대화하는 투영을 찾기보다는 클래스간의 차별성을 극대화시키는 최적의 투영행렬을 구한 후, 투영행렬을 이용하여 입력신호를 선형변환한다. LDA기법에 의한 특징추출과정을 단계별로 살펴보면 다음과 같다.

[단계 1] 측정된 학습용 전류신호를 1차원 열벡터로 변환한 후 식 (6) 및 식 (7)에 의해 BCS 행렬인  $S_B$ 와 WCS 행렬인  $S_W$ 를 구한다.

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

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

여기서,  $n_i$ 는  $i$  번째 클래스  $C_i$ 에서의 데이터 수이며,  $m_i$ 는  $i$  번째 클래스  $C_i$ 내의 평균값을 나타낸다. 또한, 식 (7)에서  $m$ 은 전체 클래스의 평균값이 된다.

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

$$W = \operatorname{argmax}_W \frac{|W^T S_B W|}{|W^T S_W W|} \quad (8)$$

$$= [w_1, w_2, \dots, w_P]$$

$$S_B w_i = \lambda_i S_W w_i, \quad i = 1, 2, \dots, P \quad (9)$$

[단계 3] 학습신호  $x_i$ 에 대한 특징벡터  $T_i$ 를 구한다.

$$T_i = W^T z_i = W^T v_i^T (x_i - m) \quad (10)$$

식 (10)에서 알 수 있는 바와 같이 선형판별분석을 위해서는 우선 PCA기법에 의해 입력신호를 저차원으로 축소한 후, 산출된 특징벡터  $z_i$ 를 최적의 투영행렬  $W$ 에 의해 LDA공간으로 투영시킨다. 일반적으로 학습신호의 수( $P$ )가 신호의 길이( $N$ )보다 적은 경우 WCS행렬  $S_W$ 는 항상 특이행렬이 된다. 이것은 사영행렬을 적당히 선택하지 않는다면 사영된 WCS행렬은 영이 될 수 있음을 의미한다. 따라서 이러한 문제점을 해결하기 위하여 PCA기법을 이용하여 입력신호를 저차원공간으로 축소한 후 선형판별분석을 수행한다.

[단계 4] 인식하고자 하는 입력전류(검증데이터)를 LDA기법에 의해 특징을 추출한다.

$$T_i' = W^T z_i' = W^T v_i^T (x_i' - m) \quad (11)$$

[단계 5] 미리 계산된 특징벡터  $T_i$ 와 입력벡터  $T_i'$ 간의 유클리드 거리를 산출한다.

그림 4는 입력신호의 고유값이 큰 순서대로 3개의 특징벡터를 PCA와 LDA로 사상시킨 결과를 나타낸다. 그림 4에서 알 수 있는 바와 같이 PCA에 의해 투영시킨 결과 운전상태별로 공간상으로 중복되는 부분이 있는 반면에 LDA에 의해 투영시킨 결과 운전상태별로 차별성이 극대화되었음을 알 수 있다. 그림 5는 SNR이 5인 백색 노이즈가 존재하는 환경

PCA와 LDA에 기반을 둔 융합알고리즘에 의한 유도전동기의 고장진단

하에서 입력신호를 PCA와 LDA로 사상시킨 결과를 나타낸다. 그림 5에서 보는 바와 같이 LDA에 의해 변환된 특징벡터는 노이즈에 의해 왜곡이 심하게 발생하여 고장상태별로 LDA 특징벡터의 차별성을 찾아볼 수 없다. 이는 PCA 특징벡터를 LDA에 의해 차별성을 극대화했기 때문에 노이즈가 없거나 적은 경우 PCA만을 이용한 경우보다 고장상태별 구분이 명확하지만, 노이즈가 어느 한계점을 지나 증가할수록 노이즈의 성분에 의해 LDA의 차별성에 왜곡이 발생하기 때문이라 분석된다. 그림 3에 최종적으로 유도전동기의 고장진단을 위한 융합모델 및 결정법칙 과정을 나타냈다.

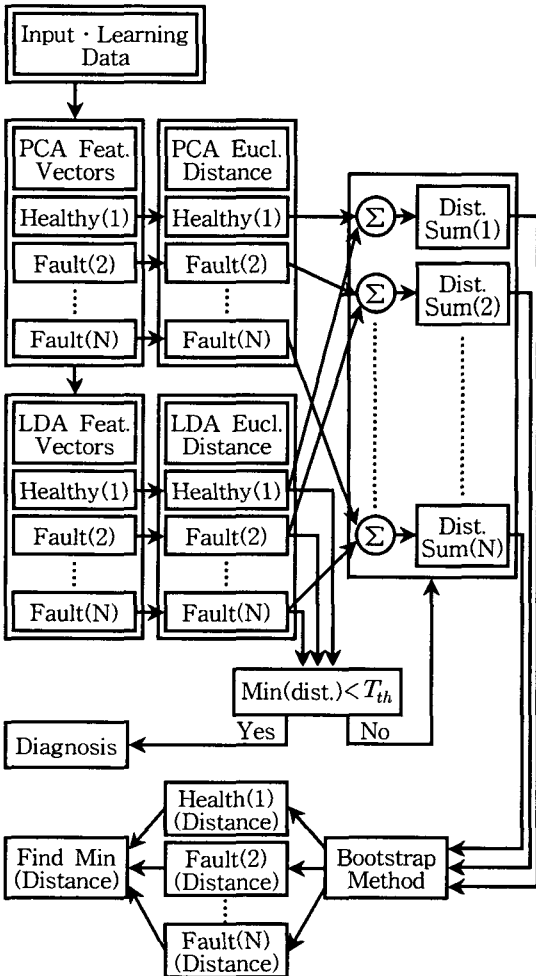




그림 3. 고장진단을 위한 융합 알고리즘  
Fig. 3. Fusion algorithm for a fault diagnosis





(a) PCA(상) (b) LDA(하)

그림 4. PCA와 LDA에 의한 특징벡터  
Fig. 4. Feature vectors by PCA and LDA

그림 4 및 5에서 알 수 있는 바와 같이 노이즈가 존재하지 않는 조건하에서는 LDA기법이 PCA기법에 비해 우수한 특성을 나타낸다. 그러나 노이즈가 존재하는 환경하에서는 LDA기법의 경우 왜곡 변형에 의해 인식을 저하를 초래하게 된다. 이러한 특성을 이용하여 노이즈가 존재하지 않는 조건하에서 LDA에 의해 결정하고 노이즈가 존재하는 환경하에서는 PCA기법과 LDA기법에 기반을 둔 확률모델의 평균값을 이용하여 결정한다. 여기서 진단방식의 선택은 미리 설정된 임계값에 의해 결정된다. 즉 노이즈가 증가할수록 유클리드 거리가 증가하므로 설정된 임계값 이하인 경우에는 LDA기법에 따르고 설정된 임계값 이상인 경우에는 확률모델에 의해 결정

하도록 하였다. 확률모델은 PCA기법과 LDA기법에 의해 산출된 유클리드 거리값을 각각 합산한 후 합산된 거리벡터들을 붓스트랩(bootstrap)방법을 이용하여 가우스 확률모델로 구축하였다[12]. 최종 인식 단계에서는 설정된 모델중 평균값이 최소인 모델을 선정하여 인식하였다.



(a) PCA(상) (b) LDA(하)

그림 5. PCA와 LDA에 의한 특징벡터(SNR=5)  
Fig. 5. Feature vectors by PCA and LDA

### 3. 실험 및 결과

유도전동기의 고장검출신호를 얻기 위해 그림 6과 같은 시험장치를 구성하였다. 그림 6에서 보는 바와 같이 시험장치는 3상 전원공급기, 시험할 전동기 및 부하장치로 구성되어 있으며, 부하제어회로는 전

력절환장치와 다른 부하패턴을 공급하기 위한 제어장치로 구성하였다. 측정전류는 입력단에서 클램프 온 미터를 통하여 디지털 오디오 테이프(DAT)에 저장하였다.




그림 6. 실험장치 구성도  
Fig. 6. Diagram of experimental setup

실험환경은 표 1과 같이 설정하였다. 표 1에서 보는 바와 같이 기본적으로 노이즈가 없는 상태에서 정상상태, 회전자 봉의 파손상태, 회전자축이 휘어진 상태, 정적편심상태 및 동적편심상태 등 6가지의 운전상태를 진단한다. 또한 노이즈가 존재하는 조건하에서 제안된 방법의 성능을 확인하기 위하여 SNR을 100에서 5까지 증가시키면서 시스템 성능을 살펴보았다.

표 1. 실험 및 진단 조건

Table 1. Condition of experiment & diagnosis

Fault ID	Fault Detection	SNR
1	Healthy	100~5
2	Faulted Bearing	"
3	Bowed Rotor	"
4	Broken Rotor Bar	"
5	Static Eccentricity	"
6	Dynamic Eccentricity	"

데이터의 샘플링 개수는 1주기당 128개이며 전체 주기는 128회이다. 이중에서 재 샘플링을 통해 운전 조건 당 18개의 사이클을 이용하였다. 최대 샘플링 주파수는 3[kHz]이고 샘플링 시간은 0.13(=

PCA와 LDA에 기반을 둔 융합알고리즘에 의한 유도전동기의 고장진단

1/(60×128)[ms]이다. 고장모델을 형성하기 위해 사용된 학습데이터는 전체 데이터 108개[(18개/운전조건당)×6조건]중 54개[(9개/운전조건당)×6조건]를 사용하였고, 모델의 검증을 위해 사용된 시험데이터는 나머지 54개 즉, 유도전동기의 고장상태별 9개의 시험데이터를 이용하였다.

표 2에 노이즈가 없는 상태에서 고장상태별 인식률을 나타냈다. 학습입력신호 및 검증신호는 LDA기법에 의해 각각 특징벡터를 산출한 후 학습특징벡터와 검증특징벡터를 산출하고 학습특징데이터와 검증특징데이터간의 유클리드 거리를 계산하여 거리가 최소인 학습모델을 선정하여 인식하였다. 표 2에서 알 수 있는 바와 같이 PCA를 적용한 경우 회전자바퀴 상태에서 취득한 9개의 데이터 중 2개가 정적편심으로 오인식되었다. 또한 정적편심에서 취득한 9개의 데이터 중 2개가 회전자바퀴 상태로 오인식되었다. 이로부터 PCA의 경우 회전자바퀴 상태와 정적편심상태를 구별하는데 한계가 있음을 알 수 있다. 반면에 LDA를 적용한 경우 검증데이터 54개에 대하여 정확한 진단을 하였다. 이것은 특징벡터를 LDA에 의해 차별성을 극대화함으로써 보다 우수한 결과를 보인 것이다.

유도전동기의 상태별 노이즈에 대한 영향을 분석하기 위한 실험결과를 표 3 및 그림 7에 나타냈다. 실험결과는 백색잡음을 임의로 10회 선택하여 평균값을 기준으로 인식률을 조사하였다. SNR이 100에서 40이상인 경우에는 노이즈의 첨가에 상관없이 인식률이 변동되지 않아 기입하지 않았다. 제안된 성능은 1) PCA만을 이용한 경우, 2) LDA만을 이용한 경우, 3) 본 논문에서 제안한 확률모델에 의한 경우로 나누어 시스템 성능을 확인하였다. 표 3 및 그림 7에서 알 수 있는 바와 같이 LDA기법을 이용한 경우 SNR이 25이상인 경우 PCA기법을 사용한 경우보다 우수한 결과를 보이지만 노이즈가 증가할수록 (SNR 20 이하) 인식률이 급격히 감소하였다. SNR이 5인 경우에는 PCA기법에 비하여 22[%] 정도 인식성능이 감소하였다. 본 논문에서 제안된 PCA와 LDA 융합모델을 적용한 결과 PCA만을 적용한 경우보다 최대 4.8[%], LDA만을 적용한 경우보다 최대 26[%] 향상된 인식결과를 나타냈다.

4. 결 론

본 논문에서는 PCA기법과 LDA기법에 기반을 둔 융합모델을 이용한 유도전동기의 고장상태 진단기법을 제안하였다. 제안된 진단기법은 PCA기법 및 LDA기법에 의해 특징을 추출한 후 진단 모델별 특징벡터와 입력벡터간의 유클리드 거리를 산출한다. 최종 진단단계에서는 PCA기법과 LDA기법에 의해 각각 산출된 두 개의 정합값을 확률모델에 의해 융합한 후 최종 검증하는 구조로 되어있다.

표 2. 인식 결과  
Table 2. Recognition results

운전상태	LDA		PCA	
	인식	에러	인식	에러
전전상태	9	0	9	0
베어링고장	9	0	9	0
회전자바퀴	9	0	7	2
회전자바고장	9	0	9	0
정적편심	9	0	7	2
동적편심	9	0	9	0

표 3. 노이즈 변화에 따른 인식결과  
Table 3. Recognition results by noise variation

SNR	PCA	LDA	PCA+LDA
35	92.6	100	100
30	91.3	98.7	98.7
25	92.22	95.17	95.17
20	88.89	85.56	90.74
15	82.78	67.96	84.82
10	72.78	51.23	77.59
5	60.56	38.52	62.96

제안된 방법의 타당성을 보이기 위해 실험한 결과, 노이즈가 존재하지 않거나 노이즈가 적은 경우 LDA기법을 이용한 경우 인식률이 100[%]로 나타나 PCA기법에 비해 최대 7[%] 정도 향상된 인식결과를 보였다. 그러나, 노이즈가 증가할수록 LDA기법을 사용한 경우 인식률이 급격히 감소하여 PCA기법에 비하여 최대 22[%] 하락된 성능을 나타냈다. 이러한 문제점을 보완하고 동시에 PCA기법과 LDA기법의 장점만을 부각시키기 위해 확률기반 판별분석기법을 적용한 결과, PCA만을 적용한 경우보다 최대 4.8[%], LDA만을 적용한 경우보다 최대 26[%]

향상된 인식결과를 나타냈다. 따라서 제안된 방법의 경우 노이즈의 존재 유무에 상관없이 우수한 성능을 보임을 확인할 수 있었다. 향후 다양한 고장데이터와 부하상태 대해서도 제안된 방법의 타당성을 살펴볼 필요성이 있을 것으로 사료된다.

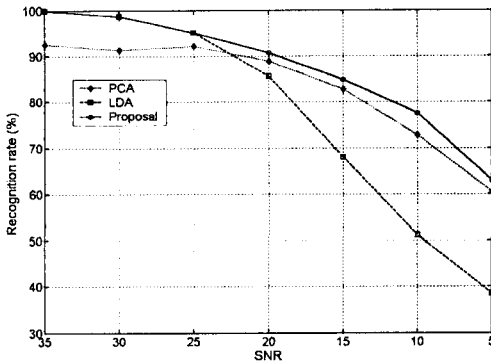


그림 7. 노이즈에 변화에 따른 인식결과  
Fig. 7. Recognition result by noise variation

본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2004-13-223)주관으로 수행된 과제임.

### References

- [1] Ye Zhongming and Wu Bin, "A review on induction motor online fault diagnosis", *PIEMC 2000*, Vol.3, pp.1353-1358, 2000.
- [2] ME.H. Benbouzid and G.B. Kliman, "What stator current processing-based technique to use for induction motor rotor faults diagnosis?", *IEEE Transactions on Energy Conversion*, Vol.18, Issue 2, pp.238-244, 2003.
- [3] W.T. Thomson and M. Fenger, "Current signature analysis to detect induction motor faults", *IEEE Industry Applications Magazine*, Vol.7, Issue 4, pp.26-34, 2001.
- [4] H. Nejari, ME.H. Benbouzid, "Monitoring and diagnosis of induction motors electrical faults using a current Park's vector pattern learning approach", *IEEE Transactions on Industry Applications*, Vol.36, Issue 3, pp.730-735, 2000.
- [5] A. Bellini, F. Filippetti, G. Franceschini, C. Tassoni, and G.B. Kliman, "Quantitative evaluation of induction motor broken bars by means of electrical signature analysis", *IEEE Transactions on Industry Applications*, Vol.37, Issue 5, pp.1248-1255, 2001.
- [6] Kyusung Kim, A.G. Parlos, and R. Mohan Bharadwaj, "Sensorless fault diagnosis of induction motors", *IEEE Transactions on Industrial Electronics*, Vol.50 Issue 5, pp. 1038-1051, 2003.
- [7] F. Zidani, M. El Hachemi Benbouzid, D. Diallo, and M.S.

- Nait-Said, "Induction motor stator faults diagnosis by a current concordia pattern-based fuzzy decision system", *IEEE Transactions on Energy Conversion*, Vol.18, Issue 4, pp.469-475, 2003.
- [8] M. Turk and A. Pentland, "Face recognition using eigenfaces", *Proc. IEEE Conf. on Computer Vision and Pattern Recognition*, pp.586-591, 1991.
- [9] P.N. Belhumeur, J.P. Hesparha, and D.J. Kriegsmann, "Eigenfaces vs. Fisherfaces : recognition using class specific Linear Projection", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7), pp.711-720, 1997.
- [10] Richard O. Duda, Peter E. Hart and David G. Stork, *Pattern Classification*, John Wiley & Sons, 2nd ed, 2002.
- [11] 전병석, 이상혁, 박장환, 유정웅, 전명근, "선형판별분석 기법을 이용한 유도전동기의 고장신단", 한국조명전기설비학회, 제18권 제4호, pp.104-111, 2004.
- [12] 손건태, *전산통계개론*, 제3판, 자유아카데미, 2003.

### ◇ 저자소개 ◇

#### 전병석 (全炳錫)

1969년 9월 25일생. 1995년 충북대학교 전기공학과 졸업. 1998년 충북대학교 대학원 전기공학과 졸업(석사). 2005년 동 대학원 졸업(박사). 2005년~현재 (주)세화폴리텍.

#### 이대중 (李大鍾)

1969년 2월 25일생. 1994년 충북대학교 전기공학과 졸업. 1997년 충북대학교 대학원 전기공학과 졸업(석사). 2002년 동 대학원 졸업(박사). 2003~2004년 충북대학교 컴퓨터정보통신연구소 연구원. 2004년~현재 University of Alberta, Postdoctor.

#### 이상혁 (李相赫)

1963년 3월 10일생. 1988년 충북대학교 전기공학과 졸업. 1991년 서울대학교 대학원 전기공학과 졸업(석사). 1998년 동 대학원 졸업(박사). 1996~1999년 (주)하우 기업부설연구소. 1999~2000년 (주)지앤씨, 2000년~현재 부산대학교 전자전기정보컴퓨터공학부 기금교수.

#### 유정웅 (柳正雄)

1941년 1월 20일생. 1965년 한양대학교 전기공학과 졸업. 1976년 단국대학교 대학원 전기공학과 졸업(석사). 1987년 동 대학원 전자공학과 졸업(박사). 1969~1979년 대전공업전문학교 부교수. 1979년~현재 충북대학교 전기전자컴퓨터공학부 교수.

#### 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.