

# 분산정보를 이용한 특징 선택과 PCA-ELM 기반의 유도전동기 고장진단 기법 개발

(Development of Induction Motor Diagnosis Method by Variance  
Based Feature Selection and PCA-ELM)

이대중\* · 전명근

(Dae-Jong Lee · Myung-Geun Chun)

## 요 약

본 논문은 클래스 내와 클래스 간의 분산정보를 이용한 주파수 성분의 선택적 추출기법과 PCA-ELM 기반의 유도전동기 고장진단 시스템을 제안한다. 제안된 방법은 취득된 전류신호를 DFT에 의해 주파수 영역으로 변환한 후 분산정보를 이용하여 고장상태별로 차별성이 큰 순서대로 주파수 성분을 추출한다. 다음 단계로 선택된 주파수 성분에 대해서 PCA를 이용하여 고장상태별 특징들을 추출한다. 마지막 단계는 학습속도가 매우 우수한 ELM분류기에 의해 유도전동기의 상태를 진단하게 된다. 다양한 부하에 대하여 몇몇의 전기적 고장과 기계적 고장 하에서 획득한 데이터를 이용하여 제안된 방법의 타당성을 검증한다.

## Abstract

In this paper, we proposed selective extraction method of frequency information and PCA-ELM based diagnosis system for three-phase induction motors. As the first step for diagnosis procedure, DFT is performed to transform the acquired current signal into frequency domain. And then, frequency components are selected according to discriminate order calculated by variance. As the next step, feature extraction is performed by principal component analysis (PCA). Finally, we used the classifier based on Extreme Learning Machine (ELM) with fast learning procedure. 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 : Feature Selection, ELM, PCA, Induction Motor, Fault Detection

---

\* 주저자 : 충북대학교 전자공학부  
Tel : 043-261-2388, Fax : 043-268-2386  
E-mail : bigbell@chungbuk.ac.kr  
접수일자 : 2010년 3월 23일  
1차심사 : 2010년 3월 26일  
심사완료 : 2010년 5월 17일

## 1. 서 론

일반적으로 유도전동기의 온라인 고장진단은 진동 신호 모니터링[1]과 MCSA (motor current signal analysis)[2-3]에 의해서 이루어진다. MCSA는 유도전동기의 전류를 분석하여 고장진단을 하는 방법으로 다양한 편리성으로 인해 현재 널리 연구되고 있다 [4-6]. 그러나 MCSA기반으로 유도전동기의 전류신호를 취득하였다 하더라도 진단을 위해 전동기의 상태를 효과적으로 표현할 수 있는 특징추출 기법이 요구된다. 특징벡터 추출기법에는 Park 변환에 의해 d-q 패턴을 추출하는 방법[7], 웨이블렛 기법을 이용한 전류신호의 시간-주파수 특징을 추출하는 방법 등이 적용되고 있다[8-9]. 그러나 d-q 패턴의 경우 다양한 고장상태별로 고유의 패턴을 얻기가 어렵고, 노이즈가 존재하는 환경 하에서 고장패턴을 분류하는데 어려움이 있다. 또한 웨이블렛에 의해 구해진 특징은 부하변동에 의해 민감한 특성을 보임으로, 부하 또는 속도가 변화하는 환경 하에서는 효과적이지 못한 단점이 있다. 이 외에도 주성분분석기법(PCA : Principal Component Analysis)을 이용하여 특징을 추출하는 방법이 사용되고 있다. 그러나 주성분분석기법은 모든 입력차원의 선형성에 기반을 두고 있기 때문에 선형 특성에 대해서는 우수한 결과를 나타내나 비선형 특성을 갖는 데이터에 대해서는 최적의 변환행렬을 구할 수 없는 문제점을 지니고 있다[10].

위에서 살펴본 바와 같이 유도전동기 고장진단을 위해 다양한 방법이 적용되고 있으나 유도전동기의 입력전류의 주파수 특성을 분석하여 전동기의 상태를 진단하는 방법이 가장 널리 적용되고 있다. 그러나 주파수 기반의 특징추출 기법을 실시간 고장진단 시스템에 적용하기 위해서는 우세한 주파수 성분들의 선택이 반드시 수행되어야 한다. 즉 입력전류에 대해 DFT(Discrete Fourier Transform)을 적용하여 주파수 성분들에 대한 정보(크기)를 산출하는데, 이 경우 대규모 입력차원을 갖는 모든 주파수 성분들을 고려하여 실시간 진단시스템을 구현하는데는 한계가 있다 [11].

이러한 한계를 해결하기 위하여 본 논문에서는 클레

스 내외 클래스 간의 분산정보를 이용한 주파수 성분의 선택적 추출기법과 PCA-ELM 기반의 유도전동기 고장진단 시스템을 제안한다. 제안된 방법은 취득된 전류신호를 DFT(Discrete Fourier Transformer)에 의해 주파수 영역으로 변환한 후 분산정보를 이용하여 고장상태별로 차별성이 큰 순서대로 주파수 성분을 추출한다. 다음 단계로 선택된 주파수 성분들에 대해서 PCA를 이용하여 고장상태별 특징들을 추출한다. 마지막 단계는 학습속도가 매우 우수한 ELM(Extreme Learning Algorithm) 분류기에 의해 유도전동기의 상태를 진단하게 된다.

## 2. 제안된 유도전동기 고장진단 알고리즘

그림 1에서는 본 논문에서 제안한 유도전동기 고장진단 알고리즘을 나타냈다. 그림 1에서 보는 바와 같이  $t_s$  초마다 영점교차점을 이용하여 10주기의 전류 신호를 검출한 후에, DFT에 의해 주파수 영역으로 변환한다. 다음 단계로 클래스 분산정보를 이용하여 고장상태별로 차별성이 크게 나타나는 주파수 성분들을 선택하고 PCA에 의해 저차원공간으로 주파수 성분을 축소한다. 최종적으로는 처리속도가 매우 빠른 ELM 기반의 신경회로망에 의해 진단이 수행된다.

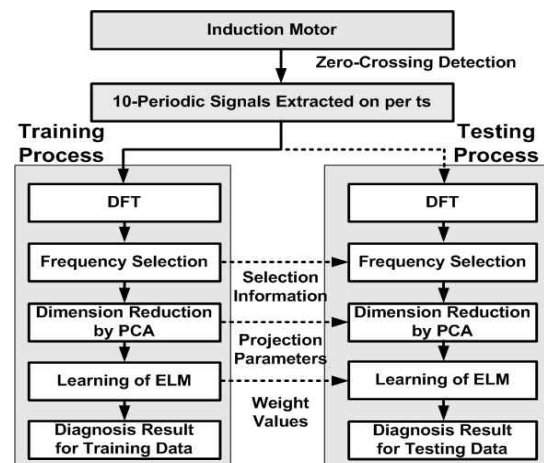


그림 1. 제안한 진단 알고리즘의 구성도  
Fig. 1. The configuration for the proposed diagnosis algorithm

## 2.1 DFT에 의한 전류신호의 주파수 변환

DFT는 시간영역의 디지털 신호를 처리하고 디지털 주파수 영역의 표현으로 변환하는데 적용될 수 있으며, 임의의 유한 수열에 대해 수치적으로 계산 가능한 최종적인 푸리에 변환으로 N개의 표본은 이산푸리에 변환계수라고 불리고, DFT 계수  $X(k)$  역시 N-점 수열이다. N점의 디지털 신호의 DFT를 정의하면 다음과 같다.

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

식 (1)을 이용하여 유도전동기의 전류신호를 주파수 공간으로 변환한다.

## 2.2 클래스 분산정보를 이용한 주파수 성분의 선택적 추출 방법

유도전동기의 전류신호를 취득한 후 DFT에 의해 주파수 공간으로 변환한 후, 클래스 분산정보를 이용하여 고장상태별로 차별성이 큰 순서대로 주파수 성분을 선택적으로 추출한다. 분산정보를 이용한 선택적 주파수 추출방법은  $i$ 번째 주파수 성분에 대한 클래스내의 분산을 나타내는 WCS(within-class scatter) 요소인  $v_{iW}$ 와  $i$ 번째 주파수 성분에 대한 클래스간 분산을 나타내는 BCS (between-class scatter) 요소인  $v_{iB}$ 를 식 (2)와 식 (3)에 의해 산출한다.

$$v_{iW} = \sum_{k=1}^c \sum_{X_i \in C_k} (X_i - m_{ik})(X_i - m_{ik})^T \quad (2)$$

$$v_{iB} = \sum_{k=1}^c n_k (m_{ik} - m_i)(m_{ik} - m_i)^T \quad (3)$$

여기서  $n_k$ 는  $k$ 번째 클래스  $C_k$ 에서의 데이터 수이며,  $m_{ik}$ 는  $i$ 번째 주파수 성분에서  $k$ 번째 클래스  $C_k$ 내의 평균값을 나타낸다. 또한 식 (4)에서  $m_i$ 은  $i$ 번째 주파수 성분에서 전체 클래스의 평균값이 된다.

식 (2)와 식 (3)을 이용하여  $i$ 번째 주파수 성분에서

식 (4)에 나타낸  $R_{vi}$  값을 산출한 후 비율의 값이 큰 순서대로 주파수 성분을 선택한다. 즉  $R_{vi}$  값이 클수록 클래스간의 분산이 크고 클래스내 분산이 작음을 의미한다. 따라서  $R_{vi}$  값을 이용하여 고장상태별로 차별성이 큰 순서대로 주파수 성분을 추출한다.

$$R_{vi} = \frac{v_B}{v_W} \quad (4)$$

## 2.3 PCA를 이용한 차원 축소 기법

PCA알고리즘은 데이터의 특징을 가장 잘 표현하는 공분산 행렬의 고유벡터를 구하여 고차원의 벡터를 줄여서 저차원의 벡터로 차원을 축소하는 기법으로 널리 사용되고 있다. 즉 PCA는 클래스 분산정보를 이용하여 선택된 주파수 정보들에 대하여 공분산 행렬을 구하여 고유벡터를 구하고, 고유값 크기 순으로 나열하여 차원을 축소하게 된다. PCA 알고리즘에 대하여 간략히 설명하면 다음과 같다.

[단계 1] 식 (5)와 같이 선택된  $p$ 개의 주파수 정보에 대한 평균을 구한다.

$$m = \frac{1}{p} \sum_{i=1}^p x_i, \quad x_i \in R^{1 \times n} \quad (5)$$

[단계 2] 학습용 주파수 정보에 대한 공분산행렬을 구한다.

$$\Omega = \overline{XX^T} \quad (6)$$

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

[단계 3] 식 (6)에 의해 계산된 공분산에 대한  $n$ 개의 고유값과  $n$ 개의 고유벡터를 구한다.

$$\Omega v_i = \lambda_i v_i \quad (7)$$

[단계 4] 고유벡터  $v_j$ 를 고려하고자 하는 차원수( $k$ )만큼 고유값의 크기 순으로 재정렬한 고유벡터  $V \in R^{n \times k}$ 를 구한 후에 주파수로 변환된 학습 데이터

$x_i$ 에 대한 특징벡터  $z_i \in R^{k \times 1}$ 를 식 (8)에 의해 산출한다. 식 (8)에서 알 수 있는 바와 같이 입력신호에 대한 특징벡터는 공분산에 대한 고유벡터를 이용하여 PCA 변환된 공간으로 투영함으로써 얻을 수 있다.

$$z_i = V^T(x_i - m)^T, \quad i = 1, 2, \dots, P \quad (8)$$

[단계 5] PCA기법에 의해 주파수로 변환된  $i$ 번째 검증 데이터  $x'_i$ 에 대한 특징벡터  $z'_i$ 를 산출한다.

$$z'_i = V^T(x'_i - m)^T \quad (9)$$

### 2.4 ELM을 이용한 진단 기법

ELM(Extreme Learning Machine)은 그림 2에서 보는 바와 같이 단일 은닉층을 가지는 전방향 신경망으로 최근 Huang 등에 의하여 제안되었다[12]. ELM에서 출력 가중치들은 다층 신경망과 같이 반복적인 학습 구조 대신에 모어-페로스의 일반화된 역행렬(Moore-Penrose generalized inverse)에 의해 분석적으로 계산된다.




그림 2. ELM의 구조  
Fig. 2. Structure of ELM

ELM의 주된 특징은 다른 신경회로망의 학습방법과 달리 반복학습을 하지 않기 때문에 전형적인 반복 학습 방법들에 비하여 매우 빠른 학습이 가능하다는 점과 ELM은 작은 학습 오차값을 가질뿐만 아니라 가중치들의 가장 작은해를 얻는 경향이 있다는 점이다. 특히 경사 기반 학습방법들이 국부최소(local minimum), 과잉적합(over-fitting)과 같은 문제점이 있는 반면에 ELM은 한 번의 학습으로 최적의 해에

직접적으로 도달하는 경향이 있다.

그림 2에서 알 수 있는 바와 같이 전방향 신경 회로망의 출력은 다음과 같이 나타낼 수 있다.

$$g(w_{ij} \cdot z_i) \cdot a_{ij} = y \quad (10)$$

여기서  $w_{ij}$ 는 은닉노드와 입력노드들을 연결하는 가중치 벡터로 임의의 값으로 초기화 되며,  $a_{ij}$ 는 은닉노드들과 출력노드를 연결하는 가중치 벡터이다.

식 (10)은 다음과 같이 간결하게 표현될 수 있다.

$$Ga = y \quad (11)$$

최종적으로 다음과 같이 최소자승법에 의하여 출력 가중치  $\hat{a}$ 을 구한다.

$$\hat{a} = G^+y \quad (12)$$

여기서  $G^+$ 는 은닉층의 출력  $G$ 의 모어-페로스의 일반화된 역행렬이다. 만일  $G^TG$ 가 비정칙인 경우,  $G$ 의 모어-페로스의 일반화된 역행렬은 다음과 같이 얻어진다.

$$G^+ = (G^TG)^{-1}G^T \quad (13)$$

## 3. 실험 및 결과

### 3.1 실험장치 구성

유도전동기 고장진단을 위해 설치한 실험장치는 그림 3에서 보는 바와 같이 유도전동기 구동부, 데이터 습득부와 고장진단부로 구성되어 있다. 세부적으로 유도전동기 구동부에는 전동기구동부, 전동기, 안전장치, 다양한 전압표시장치, 전류센서와 진동센서의 구동회로, 그리고 전기적 브레이크 기능을 갖는 부하 시스템을 갖는다. 사용된 유도전동기는 220/380[V] 4극의 0.4[kW]이다.

실험장치는 구동 전류의 불평형 및 변동을 위해 가변전압기와 가변저항기를 설치되어 있다. 또한 실제 산업 현장에서 유도전동기에 부과되는 기계적 부하를


변동시키기 위해 다이내모메타를 설치하였다. 다이내모메타는 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.



그림 3. 실험장치  
Fig. 3. A laboratory equipment

### 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) 등 네 가지 경우를 고려한다. 그림 4에서는 유도전동기의 고장부위 일부를 나타냈다.



(a) 베어링 고장

(b) 회전자 고장

그림 4. 유도전동기의 고장  
Fig. 4. Faults of induction motors

고장데이터 중에서, 그림 4 (a)에 보인 베어링 고장은 외곽 레일부분의 한 부위에 압착을 가하여 고장을 발생시켰다. 또한 그림 4 (b)에 보인 회전자는 Zhong-

ming 등이 실험한 방법과 같이 회전자의 편심에 드릴로 구멍을 내어 고장을 발생시켰다[9]. 이외에도 한 상에 3[%]의 불평형 전압을 인가하여 전압불평형 데이터를 취득하였다.

데이터 취득은 LabVIEW 상에서 영점교차점을 이용하여 1초마다 NI사의 PCI-6251 DAQ 보드를 통하여 10주기의 전류신호를 취득하였다. 데이터 취득시 샘플링 주파수의 설정은 시스템 성능에 영향을 미칠 수 있는 중요한 인자로서 본 논문에서는 20[kHz]로 설정하였으며, 따라서 한 주기 당 334개의 샘플을 취득하였다. 학습에 사용된 훈련데이터는 고장상태별로 부하를 무부하, 1.568[N·m]로 2단계로 분류하여 고장상태별로 10주기를 갖는 100개의 데이터(부하상태 2×50샘플)를 취득하였다. 검증데이터는 고장상태별로 부하를 무부하, 0.392[N·m], 0.784[N·m], 1.176[N·m], 1.568[N·m]로 5단계로 분류하여 고장상태별로 10주기를 갖는 250개의 데이터(부하상태 5×50샘플)를 취득하였다.

### 3.3 실험 결과

그림 5에서는 정상 및 고장에 따른 전류 신호에 대해 샘플 데이터 신호를 나타냈다. 그림 5에서 알 수 있는 바와 같이 시간 데이터로만으로는 고장 상태별로 차별성을 찾는 데 어려움이 있다. 그림 6에서는 고장상태별 파워 스펙트럼을 나타냈다. 시간데이터와 달리 고장상태별로 파워스펙트럼의 특성을 분석할 수 있다. 그림 6에서 보는 바와 같이 각 상태의 주파수 변환의 데이터가 모두 일치하는 경향은 아니지만 상태에 따른 다음과 같은 일반적인 경향을 볼 수 있다. 정상 상태의 주파수 특성을 보면 기본 주파수의 60[Hz]의 3배(H3), 5배(H5), 7배(H7), 9배(H9) 근처에서 피크치를 형성하는 것을 볼 수 있다. 베어링 고장은 정상 데이터에 비하여 3배, 7배에 해당하는 피크치가 감소된 것을 확인할 수 있다.

전압 불평형은 9배수 주파수 근처에서 변화하는 패턴이 정상상태와 다름을 볼 수 있으며, 회전자 고장은 피크치의 값이 3배와 5배수의 주파수대에는 변화폭이 적으며 7배수의 주파수대에는 높은 변화를 보이고 있

다. 저주파뿐만 아니라 4[kHz] 이상의 고주파 영역에서도 고장상태별로 파워스펙트럼의 차이가 발생함을 확인할 수 있다. 그러나 1[kHz]에서 4[kHz]사이에는 고장상태별로 큰 차이점이 발생하지 않음을 알 수 있다.




그림 5. 고장 상태별 전류 신호  
Fig. 5. Current signals by fault type of induction motor

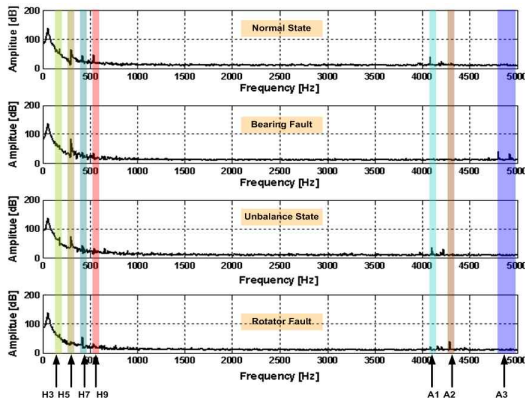


그림 6. 고장상태별 파워 스펙트럼  
Fig. 6. Power spectrum according to fault type for induction motor

그림 7에서는 DFT와 PCA를 수행한 후 ELM과 k-NN 분류기에 의한 결과를 나타냈다. k-NN 분류기는 검증데이터와 학습데이터간의 유클리디안 기반의 거리비교에 의해 진단하는 방법으로 패턴인식분야에 널리 적용되고 있다[10]. 제안된 방법의 평가를 위해 주파수 성분은 총 5,000개의 주파수 성분 중에서 차별성이 큰 순서대로 5개에서 1,000개까지 5씩 증가시키

면서 성능을 분석하였다. 그 다음단계인 PCA에서는 특징을 수를 5개로 고정하였다. 그림 7에서 보는 바와 같이 주파수 성분을 35개 선택하고 할 경우 진단율이 96.8[%]로 가장 높게 나타났다. 이는 전구간 주파수 성분을 고려한 경우의 진단율인 84.6[%]와 비교해 볼 때 매우 향상된 진단 성능을 나타냈다.

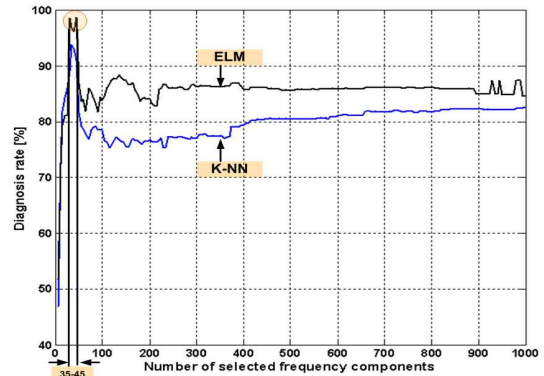


그림 7. 선택된 주파수 성분의 수에 따른 진단율  
Fig. 7. Diagnosis rate according to number of selected frequency components

표 1에서는 적용방법별 진단결과를 나타냈다. 표 1에서 H1은 정상, F1은 베어링고장, F2는 전압불평형, F3는 회전자고장을 각각 의미한다. 우선 PCA+kNN 방법은 차원이 65개일 때 진단율이 66.2[%]로 매우 저조하게 나타났다. 이는 시간영역에서 고장상태별 차별성이 크게 나타나지 않은 것에 기인한 것이라 분석된다. DFT+PCA+kNN 방법은 차원이 5일 때 진단율이 82.6[%]로 시간영역에 비하여 DFT 공간에서 차원을 축소할 경우 진단율이 16.2[%] 향상됨을 확인할 수 있다. DFT+FS+PCA+kNN(FS는 클래스간 차별성이 큰 주파수 성분을 선택을 의미)는 주파수 성분을 35개, PCA에 의한 차원축소를 5개로 하였을 때 진단율이 93.9[%]로 나타났다. DFT+FS+PCA+ELM은 주파수 성분을 35개, PCA에 의한 차원축소를 5개로 하였을 때 진단율이 96.8[%]로 나타났다. 이러한 결과로부터 유도전동기 고장진단은 시간영역보다는 주파수 공간이 효과적임을 알 수 있다. 또한 고장상태별로 차별성이 큰 속성만을 선택한 후 고장진단 알고리즘을 적용하는 것이 효과적임을 확인할 수 있다.

표 1. 적용방법별 진단결과

Table 1. Fault diagnosis result by each method

[unit : %]

Method	H1	F1	F2	F3	진단율
PCA+kNN	20.0	80.0	100	64.8	66.2
DFT+PCA+kNN	90.4	71.6	69.2	99.2	82.6
DFT+FS+PCA+kNN	92.8	98.4	85.6	98.9	93.9
DFT+FS+PCA+ELM	95.2	100	91.2	100	96.8

#### 4. 결 론

본 논문에서는 클래스 내와 클래스 간의 분산정보를 이용한 주파수 성분의 선택적 추출기법과 PCA-ELM 기반의 유도전동기 고장진단 시스템을 제안하였다. 실험결과, 제안된 방법은 PCA+kNN과 비교해 볼 때 30.6[%]의 진단률 향상을 보였다. 다양한 알고리즘과 비교분석한 결과유도전동기 고장진단은 시간영역보다는 주파수 공간이 효과적임을 알 수 있다. 또한 고장상태별로 차별성이 큰 속성만을 선택한 후 고장진단 알고리즘을 적용하는 것이 효과적임을 확인할 수 있다. 향후 인버터 등에 의해 고조파가 발생 시 고장 전류에 의한 고조파 성분과의 차이점 및 다른 유형의 전동기에 제안된 방법이 효과적으로 적용가능한지에 대한 연구가 진행되어야 할 것이다.

#### 감사의 글

이 논문은 2007년 정부(교육인적자원부)의 재원으로 한국 학술진흥재단의 지원을 받아 수행된 연구임(KRF-2007-313-D00304).

#### References

[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] Hua Su and et al, "Induction Machine Condition Monitoring Using Neural Network Modeling," IEEE Trans. Industrial Electronics, vol. 54, no. 1, pp.241-264, 2007.  
 [4] Antonino-Daviu, and et al, "Influence of Nonconsecutive

Bar Breakages in Motor Current Signature Analysis for the Diagnosis of Rotor Faults in Induction Motors," IEEE Trans. Energy Conversion, vol. 25, no. 1, pp.80-89, 2010.  
 [5] Van Tung Tran, Bo-Suk Yang, Myung-Suck Oh, Andy Chit Chiow Tan, "Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference," Expert Systems with Applications, vol. 36, no. 9, pp.1840-1849, 2009.  
 [6] Vilas N. Ghatge, Sanjay V. Dudul, "Optimal MLP neural network classifier for fault detection of three phase induction motor," Expert Systems with Applications, vol. 37, no. 4, pp.3468-3481, 2010.  
 [7] Nejari, 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.  
 [8] Zhengping Zhang, and et al, "A Novel Detection Method of Motor Broken Rotor Bars Based on Wavelet Ridge," IEEE Trans. on Energy Conversion, vol. 18, vol. 3, pp.417-423, 2003.  
 [9] Zhongming Ye, and et al, "Current Signature Analysis of Induction Motor Mechanical Faults by Wavelet Packet Decomposition," IEEE Trans. on Industrial Electronics, Vol. 50, No. 6, December, 2003.  
 [10] Richard O. Duda et al, Pattern Classification, John Wiley & Sons Inc, 2nd Ed., 2002.  
 [11] R. Casimir, and et al, "The Use of Feature Selection and Nearest Neighbors rules for Faults Diagnostic in Induction Motors", Engineering Applications of Artificial Intelligence, vol. 19, pp.169-177, 2006.  
 [12] G. B. Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: theory and applications," Neurocomputing, Vol. 70, No. 1-3, pp. 489-501, 2006.

#### ◇ 저자소개 ◇



##### 이대중 (李大鍾)

1969년 2월 25일생. 1995년 충북대학교 전기공학과 졸업. 1997년 충북대학교 전기공학과 졸업(석사). 2002년 충북대학교 전기공학과 졸업(박사). 2006년~현재 충북대학교 전자공학부.



##### 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 자동차연구소 선임연구원. 2000~2001년 University of Alberta 방문교수. 1996년~현재 충북대학교 전자공학부.