

# 진동 및 전류신호의 데이터융합을 이용한 유도전동기의 결함진단 Fault Diagnosis of Induction Motors Using Data Fusion of Vibration and Current Signals

양 보 석† · 김 광 진\* · 한 천\*

Bo-Suk Yang, Kwang Jin Kim and Tian Han

(2004년 4월 21일 접수 : 2004년 9월 23일 심사완료)

**Key Words** : Dempster-Shafer Theory(D-S 이론), Data Fusion(데이터 융합), Feature Extraction(특징추출), Neural Network(신경망), Fault Diagnosis(결함진단), Electric Motors(전동기), Vibration(진동), Stator Current(고정자 전류)

## ABSTRACT

This paper presents an approach for the monitoring and detection of faults in induction machine by using data fusion technique and Dempster-Shafer theory. Features are extracted from motor stator current and vibration signals. Neural network is trained and tested by the selected features of the measured data. The fusion of classification results from vibration and current classifiers increases the diagnostic accuracy. The efficiency of the proposed system is demonstrated by detecting motor electric and mechanical faults originated from the induction motors. The results of the test confirm that the proposed system has potential for real time application.

### 기 호 설 명

- $a^i, \gamma^i$  : 대표 패턴과 관련된 파라미터
- $d^i$  : 입력벡터와 대표 패턴의 유클리드 거리
- $E_v(\mathbf{x})$  : 입력벡터  $\mathbf{x}$  의 출력오차
- I : 비정규 또는 결합 법칙
- $L_i$  : 인공신경망의 각 층(layer)
- $m$  : 기본 신뢰 배정값(basic belief assignment)
- $p^i$  : 대표 패턴(prototypes)
- $s^i$  : 활성화함수(activation)
- $u_q^i$  : 대표 패턴의 클래스 소속도(membership)
- $\omega$  : 클래스
- $\mathbf{x}$  : 입력벡터

- $\phi^i$  :  $d^i, \gamma^i$ 에 따른 감소지수함수
- $\Omega$  : 분별 프레임(FOD; frame of discernment)
- $\oplus$  : 정규화 결합(normalized rule of combination)

## 1. 서 론

산업현장에는 설치의 간편함과 높은 운전 신뢰성 때문에 펌프, 압축기, 팬 등의 각종 회전기계의 구동 장치로서 유도전동기가 널리 사용되고 있다. 비록 유도전동기가 높은 신뢰성을 가지고 있다고 하더라도, 다양한 요인에 의해 결함이 발생할 수 있다. 즉, 일반 회전기계에서 공통으로 발생하는 불평형, 정렬불량, 베어링 결함 등의 기계적 결함과, 전자기력에 기인하는 회전자 봉 결함, 공극 편심, 고정자 결함 등의 전기적인 결함들이 발생하게 되고, 이는 전동기의 수명, 제품의 품질 및 성능을 저하시키게 된다.<sup>(1~4)</sup>

전동기의 상태감시 및 결함진단에는 진동분석, 고정자 전류분석, 축방향 자속분석, 부분방전, 유효유

† 책임저자 : 정희원, 부경대학교 기계공학부  
E-mail : bsyang@pknu.ac.kr  
Tel : (051) 620-1604, Fax : (051) 620-1405

\* 부경대학교 대학원 기계공학부

마멸입자분석, 냉각가스분석 등이 사용되고 있다.<sup>(5)</sup> 이 중에서 주로 진동분석 방법이 베어링, 회전자 및 고정자 결합의 분석방법으로 널리 사용되어 왔으나, 회전자 봉의 결합에 대해 명확한 특징을 나타내지 못하는 단점이 있다. 한편 전류신호분석(motor current signature analysis: MCSA)은 1989년 Haynes에 의해 제안되어 회전자 봉과 공극 편심의 결합진단에 사용되어 왔다.<sup>(6)</sup>

이들 기술은 주로 정비프로그램의 수행을 위한 독립된 단일 기술로 이용되는 경향이었으나, 최근에는 중요 설비를 모두 감시하거나 진단 정도를 높이기 위해서는 하나의 단일 기술로는 불가능하고, 여러 기술의 조합이 필요하다는 것이 널리 인식되고 있다.

결합 진단에서는 먼저 기계의 상태를 나타내는 특징량을 추출하기 위해 선택된 변환기(transducer) 또는 센서(sensor)를 이용하여 물리적인 양을 전기신호로 변환하고, 이들 신호로부터 특징추출(feature extraction)과 특징선택(feature selection)과정을 통하여 유효한 특징들을 추출한다. 그리고 이들 특징을 분류기(classifier)를 통하여 학습(training)을 실시하고 미지 신호의 특징 정보(데이터)를 분류기를 통하여 어느 결합패턴에 소속되는지의 분류를 수행하게 된다.

통상 진단시스템의 성능은 사용되는 센서의 신뢰도와 감지된 신호로부터 추출된 특징에 의해 주어지는 자유도에 크게 영향을 받는다. 장비의 물리적, 공간적인 한계로 종종 한 종류의 센서에 의해 부분적인 정보만을 제공하게 된다. 이러한 단점들로 하나의 센서로는 제품 성능과 대상 환경에 대한 일관된 정보를 제공하지 못하는 자료의 불확실성(uncertainty)이 있다. 또한, 단일 센서에서 센서의 열화, 주위 잡음의 영향 등과 동적인 환경에서 필요한 정보를 신뢰할 수 있게 취득할 수 없는 정보의 불확실성 문제도 존재한다.<sup>(7, 8)</sup>

이 논문에서는 유도전동기의 결합 진단에 대한 진단 정도와 신뢰도를 향상시키기 위해, 정보 융합(information fusion)<sup>(7-10)</sup> 기술을 적용한 새로운 진단기법을 제시한다. 즉, 전동기에서 진동신호와 고정자 전류신호를 취득하여 그 특징들을 추출하고, 이들 특징에 대해 분류기로서 신경망을 이용하여 각각의 상태분류 결과를 정량적으로 평가한다. 그리고 증거이론(evidence theory)의 하나인 Dempster-Shafer이

론<sup>(11, 12)</sup>을 적용하여 두 분류결과를 결정레벨(decision level) 단계에서 분류결과를 융합하여 보다 향상된 진단 정도를 얻는 진단 알고리즘을 제안한다. 마지막으로 실제 유도전동기의 결합에 적용하여 그 유용성을 단일 센서 정보를 이용한 분류결과와 비교하여 검토한다.

## 2. 이론적 배경

### 2.1 데이터 융합

최근 다중 센서(multi-sensor)의 데이터 융합기술은 민간 및 군사 부문의 응용을 위해 지대한 주목을 받고 있다. 데이터 융합기술은 다중 센서와 연관된 데이터 베이스로부터 데이터를 결합하는 기술로서, 하나의 센서를 사용하는 것보다 향상된 정확도와 더 많은 특별한 추론(inference)을 이끌어낼 수 있는 장점이 있다.

일반적으로 여러 정보원, 즉 센서들로부터 취득된 각종 정보(특징량)들을 결합하는 데는 여러 문제점들이 발생할 수 있다. 특히 다른 여러 센서들로부터 제공된 정보들을 결합하는 경우, 여러 정보원이 관심 데이터에 대한 부정확 또는 불확실한 정보를 제공하는 다중 소스정보시스템 및 종합되는 수치적 파라미터에 대한 전문가들마다 각기 다른 설명을 나타내는 분야에서 정보 경쟁(conflict)이라는 문제가 발생하게 된다.

조잡하고 부족하며 정확성이 결여된 정보 상황에서 확률적 모델에 바탕을 둔 데이터 융합 방법은 문제를 처리하는데 항상 만족할만한 결과를 제공할 수 없다. 이에 유용한 정보의 특성에 근거해서 정보를 표현하기 위한 모델로 확률이론과 증거이론에 근거한 믿음함수(belief function), 상(upper) 및 하확률(lower probability) 등의 정량적 모델, 가능성(possibility)이론 및 비단조 추론(non-monotonic inference) 등의 정성적 모델이 제안되고 있다.<sup>(7, 8)</sup>

### 2.2 Dempster-Shafer 이론

증거이론은 상 및 하 확률분포에 관한 Dempster의 연구<sup>(13)</sup>에 기초하고 있다. 불확실한 지식을 모델링하기 위한 믿음함수의 유용성이 Shafer<sup>(14)</sup>에 의해서 연구되었다. 증거이론은 먼저 분별 프레임(FOD: frame of discernment)이라 불리는 가설집합  $\Omega$ 를 제시한다.

$$\Omega = \{A_1, \dots, A_n, \dots, A_N\} \quad (1)$$

이는 서로 배타적이고 전역적인  $N$ 개의 가설로 구성되어있다. 분별프레임으로부터  $2^N$ 개의 명제로 구성된 멱집합  $2^\Omega$ 를 고려하면 식 (2)와 같다.

$$2^\Omega = \{\emptyset, \{A_1\}, \{A_2\}, \dots, \{A_N\}, \{A_1 \cup A_2\}, \dots, \Omega\} \quad (2)$$

증거이론에서 중요한 기본신뢰배정함수(BAA: basic belief assignment)는 식 (3)과 같이  $\Omega$ 의 멱집합  $2^\Omega$ 에  $[0, 1]$ 의 값을 사상하는 함수  $m$ 으로 주어지고 식 (4)와 같은 특징을 갖는다.

$$m_j : 2^\Omega \rightarrow [0, 1] \quad (3)$$

$$m_j(\emptyset) = 0, \quad \sum_{A \subseteq \Omega} m_j(A) = 1 \quad (4)$$

여기서  $m$ 이 1이면 증거는 완전하고, 0이면 거짓 증거를 의미한다.

$\Omega$ 의 원소에 배정된 믿음의 크기(mass)는 확률분포와 유사하지만, 단위 크기가  $2^\Omega$ 의 원소에 분배된다는 사실이다. 즉,  $\Omega$ 내의 한 원소집합(singleton)뿐만 아니라 복합가설(composite hypothesis)에도 분배되는 것이다.  $m_j(A) > 0$ 인 전체집합  $\Omega$ 의 부분집합  $A$ 를  $m$ 의 관심원소(focal element)라 한다.  $m$ 과 관련된 믿음함수  $Bel(A)$ 와 개연성함수(plausibility function)  $Pl(A)$ 는 다음 식과 같이 정의된다.

$$Bel_j(A) = \sum_{B \subseteq A} m_j(B) \quad (5)$$

$$Pl_j(A) = \sum_{B \cap A \neq \emptyset} m_j(B) \quad (6)$$

$Bel_j(A)$ 는 가설  $A$ 가 참(true)임을 나타내는 믿음의 전체적인 척도로써 판단될 수 있다.  $Pl_j(A)$ 는 유용한 추가적인 정보가 제공되어지면 잠재적으로  $A$ 에 할당될 수 있는 믿음의 크기를 나타낸다.

정보원인  $S_j$ 로부터 제공된 BBA  $m_j$ 는 결합법칙에 의해 각 정보원의 지식을 종합하여 결합된 크기를 제공한다. 믿음의 크기(belief mass)는 각 정보원으로부터 주어진 믿음함수에 내포되어있는 전체 지식을 이용하여 결정과정에 이용될 수 있다. 2개의 독립적인 증거체로부터 얻어진 BBA의  $m_1$ 과  $m_2$ 는 직교합(orthogonal sum)이라 불리는 Dempster의 조합법칙

(combination rule)에 의해서 새로운 BBA  $m = m_1 \oplus m_2$ 를 도출하게 되고 식 (8)과 같이 정의된다.

$$m(\emptyset) = 0 \quad (7)$$

$$m(A) = \frac{\sum_{B \cap C = A} m_1(B)m_2(C)}{\sum_{B \cap C \neq \emptyset} m_1(B)m_2(C)} = \frac{m(A)}{1 - m(\emptyset)} \quad (8)$$

결합법칙에 있어서 필요충분조건은  $B \cap C \neq \emptyset$ 인  $\Omega$ 의 부분집합  $B$ 와  $C$ 가 존재해야 하는 것이다. 즉,  $m_1(B) \neq 0$ 과  $m_2(C) \neq 0$  조건이 필요하다. 이런 경우,  $m_1$ 과  $m_2$ 는 결합 가능하다고 한다. 이와 달리, Smets는 비정규화 법칙인 결합법칙(conjunctive rule) I를 제안하였고,<sup>(15)</sup> 이는 모든  $A \subseteq \Omega$ 에 대해서 식 (9)와 같이 정의된다.

$$m = m_1 \cap m_2 \Leftrightarrow m(A) = \sum_{B \cap C = A} m_1(B)m_2(C) \quad (9)$$

Smets의 결합법칙을 이용하게 되면 양의 크기가 공집합(empty set)에 할당될 수 있는데, 이것은 식 (4)를 위반하게 된다. 그래서 비정규화 법칙을 이용하는 경우, 믿음함수의 정의는 식 (10)과 같이 표현되고, 공집합에 할당되는 BBA  $m(\emptyset)$ 는 식 (11)과 같이 정의된다.

$$Bel(A) = \sum_{\emptyset \neq B \subseteq A} m(B), \quad \forall A \in \Omega \quad (10)$$

$$m(\emptyset) = \sum_{B \cap C = \emptyset} m_1(B) m_2(C) \quad (11)$$

식 (8)과 식 (11)에서  $m(\emptyset)$ 의 크기는 두 정보원  $S_1$ 과  $S_2$  사이의 경쟁을 나타낸다. 공집합에 0의 크기가 할당되는 특성을 만족시키기 위해 식 (8)의 우변과 같이 정규화 시키게 되고, 그리하면  $m_1$ 과  $m_2$ 는 경쟁하지 않는 것으로 고려되어진다.

전체집합  $\Omega$ 에서 하나의 가설을 선택하는 결정과정에 대한 문제는 믿음함수와 개연성함수가 하나의 가설에 대해서 다른 순위(ranking)를 유도하기 때문에 발생한다. 즉,  $\Omega$ 의 부분집합  $A$ 와  $B$ 에 대해서  $Bel(A) < Bel(B)$ 인 반면  $Pl(A) > Pl(B)$ 이 가능하기 때문이다. 이런 이유로 해서 믿음함수는 결정과정에 있어서 확률함수로 변하게 된다. 모든  $A \subseteq \Omega$ 에 대한  $A$ 의 원소에  $m(A)$ 의 BBA를 동등하게 분

배하는 Pignistic변환이 Smets<sup>(15)</sup>에 의해 제안되었고 식 (12)와 같이 정의된다.

$$BetP(\omega) = \sum_{\omega \in A} \frac{m(A)}{|A|}, \quad \forall \omega \in \Omega \quad (12)$$

BBA  $m$ 을 얻는 대부분의 모델은 근방정보를 이용하는 것이다. 이 논문에서는 Denoeux의 모델(11)을 이용하고 2.3절에 그 알고리즘을 설명한다.

### 2.3 분류화 알고리즘

기지의  $P$ 차원 패턴  $N$ 개로 구성된 훈련집합  $X$ 를 이용하여 패턴  $\mathbf{x}$ 를  $M$ 개의 클래스  $\omega_1, \dots, \omega_M$ 에 분류화 하는 경우를 고려하자. 각 훈련벡터  $\mathbf{x}^i$ 와 입력패턴  $\mathbf{x}$ 의 거리  $d$ 를 계산하여  $\mathbf{x}$ 의 클래스에 관한 증거로써 고려하게 된다. 이 증거는 분별프레임  $\Omega = \{\omega_1, \dots, \omega_M\}$ 에 대해서 BBA  $m^i$ 로 표현되어진다.  $\mathbf{x}^i$ 가 클래스  $\omega_q$ 에 소속되면 단위 크기(unit mass)가  $\Omega$ 의 두 부분집합 즉,  $\{\omega_q\}$ 와  $\Omega$  자체에 분배되어진다. 훈련집합 내에서 최근접(nearest neighbors: NN) 탐색의 계산 복잡성이  $k$ -NN<sup>(12)</sup>법의 단점으로 알려져 있다. 이러한 문제점은 제한된 수의 대표패턴(representative patterns 또는 prototypes)의 형태로 훈련집합을 종합함으로써 경감된다. 클래스에 패턴할당은  $n$ 개의 대표패턴  $\mathbf{p}^1, \dots, \mathbf{p}^n$ 과의 거리를 계산함으로써 구해진다. 각각의 대표패턴  $i$ 는 각 클래스  $\omega_q$ 에 소속도  $u_q^i (\sum u_q^i = 1)$ 를 가진다. 특별한 경우, 클래스  $q$ 에 대표패턴의 소속도  $u_q^i = 1$ 이 할당된다 ( $1 \neq q$ 에 대해서  $u_q^i = 0$ ).

$\mathbf{x}$ 의 클래스 소속도에 관한 불확실성을 나타내는 BBA는 다음과 같이 3단계로 계산된다.

Step 1 : 입력패턴  $\mathbf{x}$ 와 각 대표패턴 벡터  $\mathbf{p}^i$  사이의 Euclidean 거리  $d^i$ 가 식 (13)으로 계산된다.

$$d^i = \|\mathbf{x} - \mathbf{p}^i\|, \quad i=1, \dots, n \quad (13)$$

Step 2 : 각각의 대표패턴에 의해 제공되는 정보는  $\mathbf{p}^i$ 의 클래스 소속도와 거리  $d^i$ 에 근거한 BBA  $m^i$ 로 나타내어진다.  $m^i(\{\omega_q\})$ 와  $u_q^i$  사이의 비례성을 고려하여 다음 식으로 계산된다.

$$\forall q \in \{1, \dots, M\} \quad m^i(\{\omega_q\}) = \alpha^i u_q^i \phi^i(d^i) \quad (14)$$

$$m^i(\Omega) = 1 - \alpha^i \phi^i(d^i) \quad (15)$$

$$\phi^i(d^i) = \exp(-\gamma^i (d^i)^2) \quad (16)$$

여기서  $\phi^i$ 는 0과 1사이의 값을 갖는 감소함수이고,  $\alpha^i$ 는 대표패턴  $i$ 와 관련된 파라미터( $0 < \alpha^i < 1$ )이며,  $\gamma^i$  또한 대표패턴  $i$ 와 관련된 양의 값을 갖는 파라미터이다. 각각의 대표패턴의 클래스 소속도  $u_q^i > 0$ 인 클래스  $\omega_q$ 에 양의 크기가 할당되고 식 (17)과 (18)을 만족하는 식으로 구성된다.

$$\sum_{A \subseteq \Omega} m^i(A) = \sum_{q=1}^M m^i(\{\omega_q\}) + m^i(\Omega) = 1 \quad (17)$$

$$m^i(\emptyset) = 0 \quad (18)$$

Step 3 :  $n$ 개의 BBA의  $m^i$ 는 결합법칙 또는 Dempster의 법칙에 의해서 결합된다. 전자는 비정규화된 BBA  $m=I \quad m^i$ , 후자는 정규화된 BBA로 다음과 같이 정의된다.

$$m' = \bigoplus_{i=1}^n m^i, \quad m' = m/K \quad (19)$$

$$K = \sum_{q=1}^M m(\{\omega_q\}) + m(\Omega) \quad (20)$$

입력패턴  $\mathbf{x}$ 에 대한 소속 클래스의 결정은 식 (21)을 만족하는  $D(\mathbf{x}) = \omega_r$ 이 된다.

$$m'(\{\omega_r\}) = \max_q m'(\{\omega_q\}) \quad (21)$$




Fig. 1 Connectionist implementation of the evidence-theoretic classifier

분류화 알고리즘은 Fig. 1과 같이 1개의 입력층 (input layer) L<sub>1</sub>, L<sub>2</sub>, L<sub>3</sub>의 2개의 은닉층(hidden layer) 및 출력층(output layer) L<sub>4</sub>로 연결된 Radial Based Function(RBF)신경망의 형태로 구성되어 있다.<sup>(15, 16)</sup> L<sub>2</sub>에서 L<sub>3</sub>까지의 각 층은 앞의 Step 1부터 Step 2의 과정을 표현한 것이다.

(1) 은닉층 L<sub>2</sub>는  $i=1, \dots, n$ 에 대해서 활성화함수  $s^i = \alpha^i \exp\{-\gamma^i (d^i)^2\}$ 의  $n$ 개 units를 포함하고 있다. 훈련집합으로부터 대표패턴  $p_k^i$ ,  $\alpha^i$  및  $\gamma^i$ 의 벡터가 구성되고 테스트 데이터가 입력되면  $s^i$ 의 값을 계산하게 된다.

(2) 은닉층 L<sub>3</sub>은 각 대표패턴에 관련된 BBA  $m^i$ 를 계산한다. 전체집합  $\Omega$ 와  $\Omega$  내의 클래스  $\omega_q$ ,  $q=1, \dots, M$ 에 대해서  $M+1$  units의  $n$ 개의 모듈로 구성되어 있다. 모듈  $i$ 는 이전 층의 뉴런  $i$ 와 연결되어 있고, 클래스  $\omega_q$ 와 관련된 대표패턴의 소속도  $u_q^i$ 로부터 믿음 크기에 해당하는  $m^i = (m_1^i, \dots, m_{M+1}^i)^t$ 를 계산하게 된다.

$$\begin{aligned} \mathbf{m}^i &= (m^i(\{\omega_1\}), \dots, m^i(\{\omega_M\}), m^i(\Omega))^t \\ &= (u_1^i s^i, \dots, u_M^i s^i, 1 - s^i)^t \end{aligned} \quad (22)$$

(3)  $n$ 개의 BBA  $m^i$ 는 Fig. 2와 같이  $M+1$ 개의  $\Sigma$ - $\Pi$  units의  $n$ 개의 모듈로 구성된 출력층 L<sub>4</sub>에서 계산되어진다. 모듈  $i$ 의 활성화벡터  $\bar{\mu}^i = (\mu_1^i, \dots, \mu_{M+1}^i)^t$ 는 식 (23)과 같이 정의된다.




Fig. 2 Details of incoming connections to module  $i$  of layer L<sub>3</sub>

$$\bar{\mu}^i = (\mu^i(\{\omega_1\}), \dots, \mu^i(\{\omega_M\}), \mu^i(\Omega))^t \quad (23)$$

여기서  $\mu^i$ 는 BBA의  $m^1, \dots, m^i$ 의 결합이다.

$$\mu^1 = m^1 \quad (24)$$

$$\mu^i = \bigcap_{k=1}^i m^k = \mu^{i-1} \cap m^i, \quad i=2, \dots, n \quad (25)$$

Fig. 2의 L<sub>4</sub> 내에서 모듈  $i-1$ 과 L<sub>3</sub>의 모듈  $i$ 로부터 입력이 있으면 L<sub>4</sub>의  $i > 1$ 인 모듈의 각각의 요소를 계산하는 것이다. 즉,  $i=2, \dots, n$ 에 대한 활성화벡터는 다음 식에 의해 반복적으로 계산된다.

$$\mu_j^i = \mu_j^{i-1} m_j^i + \mu_j^{i-1} m_{M+1}^i + \mu_{M+1}^{i-1} m_j^i, \quad j=1, \dots, M \quad (26)$$

$$\mu_{M+1}^i = \mu_{M+1}^{i-1} m_{M+1}^i \quad (27)$$

(4) 위의 과정을 통해 분류기의 출력벡터  $\mathbf{m} = (m_1, \dots, m_{M+1})^t$ 는 다음과 같이 정의된다.

$$\mathbf{m} = \mu^n \quad (28)$$

$$\mathbf{m}' = \mathbf{m} / K, \quad K = \sum_{k=1}^{M+1} m_k \quad (29)$$

## 2.4 파라미터 학습

$\mathbf{x} \in \omega_q$ 인 입력 패턴  $\mathbf{x}$ 의 목표치 벡터를  $\mathbf{t} = (t_1, \dots, t_M)^t$ ,  $t_j = \delta_{jq}$ 라 두고, 출력값의 오차는  $\mathbf{t}$ 와 분류기의 출력벡터  $\mathbf{m}$  또는 정규화된 출력벡터  $\mathbf{m}'$ 를 비교하는 것으로 정의된다.  $\mathbf{m}$ 은  $M+1$ 의 원소로 구성된 반면,  $\mathbf{m}'$ 는  $M$ 개의 원소이기 때문에 전체집합  $\Omega$ 에 할당된 크기를  $\Omega$ 내의 클래스  $\omega_q$ ,  $q=1, \dots, M$ 에 분배하게 한다. 그래서 변형된 출력벡터  $\mathbf{P}_v = (P_{v,1}, \dots, P_{v,M})^t$ 는 다음과 같이 정의된다.

$$P_{v,q} = m_q + v m_{M+1}, \quad q=1, \dots, M \quad (0 \leq v \leq 1) \quad (30)$$

$P_{0,q}$ ,  $P_{1,q}$  및  $P_{1/M,q}$ 는 BBA  $m$ 에 대해서 각각 클래스  $\omega_q$ 의 믿음, 개연성 및 Pignistic 확률을 나타낸다. 주어진  $v$ 와 입력패턴  $\mathbf{x}$ 의 출력오차  $E_v(\mathbf{x})$ 는

$$E_v(\mathbf{x}) = \frac{1}{2} \|\mathbf{P}_v - \mathbf{t}\|^2 = \frac{1}{2} \sum_{q=1}^M (P_{v,q} - t_q)^2 \quad (31)$$

크기  $N$ 의 전체 훈련집합  $\mathbf{x}$ 의 평균출력오차는 식 (32)로 정의되고, 오차를 최소화하는 파라미터 학습을 하게 된다.

$$E_v = \frac{1}{N} \sum_{\mathbf{x} \in \mathbf{X}} E_v(\mathbf{x}) \quad (32)$$

정규화된 출력벡터  $\mathbf{m}'$ 를 이용한다면, 이에 상응하는 변형된 출력벡터  $\mathbf{P}'_v$ 와  $E'_v$ 는 같은 방식으로 정의되어 진다.

파라미터  $p^i_k$ ,  $\alpha^i$ ,  $\gamma^i$  및  $\mu^i_j$ 는 식 (33)의 구속조건 하에  $E_v$  또는  $E'_v$ 를 최소화 시키기 위해서 조절되어질 수 있다.

$$\gamma^i > 0, \quad 0 < \alpha^i < 1, \quad \sum_{j=1}^M \mu^i_j = 1, \quad 1 \leq i \leq n \quad (33)$$

### 3. 진단 시스템

Fig. 3은 이 연구에서 제안한 진단 시스템의 개략도를 나타낸다. 진동 가속도계와 전류 프로브를 이용하여 전동기의 진동 및 전류신호를 취득하고, 이들 신호로부터 특징추출과 특징선택을 통하여 유효한 특징들을 추출한다. 그리고 이들 특징을 각각의 분류기를 통하여 학습을 실시하고 미지 신호의 특징 정보(데이터)를 분류기를 통하여 어느 결합패턴에 소속되는지의 분류를 수행한다. 각 분류기는 Dempster-Shafer이론에 따라 테스트 패턴에 대한 패턴 할당을 BBA  $m$ 이라는 정량적 믿음의 양으로 주어진다. 최종적으로 각 분류기로부터 얻어진 믿음함수의 결과를 결정레벨에서 데이터 융합을 통하여 하나의 믿음함수로 결합진단 결과를 나타낸다.




Fig. 3 Diagnostic system

### 4. 실험 및 테스트 결과

제안된 알고리즘의 분류성능을 확인하기 위해 소형 3상 유도전동기(0.5 HP, 220 V, 3560 rpm)를 이용한 실험장치를 Fig. 4와 같이 구성하였다. 이 연구에서는 유도전동기의 결함을 분류하기 위해서 진동신호와 고정자 전류신호를 이용하였고, 다음의 과정에 따라 수행되었다. 먼저 신호 데이터를 취득한 후에 특징을 추출하고 추출된 특징들 중에 각각의 결함을 분류하기에 용이한 특징 선택과정을 거치며 최종 선별된 특징들로부터 데이터를 훈련시키고 마지막으로 결합분류를 수행하였다. 부하를 위해, V벨트와 풀리로 연결된 축에 부착된 블레이드의 피치를 인공적으로 변경이 가능한 휠을 설치하고 피치각의 변경을 통하여 부하를 변경하였다.

#### 4.1 데이터 취득

부하측 베어링 하우징에 축방향, 수평방향 및 수직 방향으로 가속도 센서를 부착하여 진동가속도신호를 취득하였으며, 3상 전원공급용 리드선의 각각에 3개의 클램프 전류계를 연결하여 전류신호를 취득하였다.

실험조건으로는 Table 1에 나타난 정상 및 7가지의 인공결함에 대해서 실험을 수행하였다. 기계적 불평형은 전동기 회전자의 단락 링(end ring) 축에 15.64 g · cm의 불평형 질량을 부착하였고, 편심 및 편각 정렬불량은 좌우의 베어링의 외경면과 접하는 하우징 내면을 슬롯 형상으로 가공하여 회전자 축을 수평방향으로 미세 조정할 수 있도록 하고, 두 베어




Fig. 4 Experimental apparatus

링을 동위상(in-phase)으로 조정하여 0.1 mm의 편심 정렬불량을, 서로 180° 역위상으로 조정하여 0.48°의 편각 정렬불량이 되도록 하였다. 또한 회전자 봉 12개를 직경 5 mm, 길이 15 mm로 홈을 가공하여 인위적으로 파손시켰고, 굽힌 회전자(bowed rotor)는 축 중앙에서 0.075 mm의 처짐이 발생하도록 정적 변형을 가하였다. 상 불평형은 리드선의 하나에 저항선을 부가하여 전압 불평형을 발생시켰다. 아울러 베어링결합은 외륜의 전동면에 인공적인 결함을 가공하였다.

최대 측정주파수는 3 kHz로 설정하고 샘플링 개수는 16384개로 하였다. 각각의 결합조건에 대해서 20개의 연속 시간신호를 취득하여 총 160개의 샘플을 취득하였다.

### 4.2 특징 추출

이 연구에서는 특징추출을 수행하기 위해, 측정된 진동 및 전류신호의 시간영역과 주파수영역의 데이터에 대해서 통계적 방법이 이용되었다. 사전 검토를 통하여 결합 분류에 효과적인 특징량으로 가속도 신호에 대해서는 수평방향의 센서로부터 시간영역 신호의 실효치(RMS), 첨도(kurtosis) 및 entropy estimation을, 전류신호에 대해서는 RMS, entropy estimation 및 주파수 영역의 RVF(root variable square)의 총 6개의 특징량을 선택하였다.

### 4.3 진단 결과

3.1절에서 각각의 8가지 실험조건에 대해서 취득된 각 20개의 샘플 중 15개는 훈련용 데이터로, 5개는

테스트용 데이터로 사용하였다. 이렇게 해서 총 120개의 훈련데이터와 40개의 테스트 데이터를 얻게 된다. 하나의 데이터는 4.2절과 같은 특징추출을 거쳐 3차원 벡터로 표현되고 120개의 데이터는 2.3절에서 설명한 3차원 대표패턴을 구성하게 된다. 이들 데이터는 k-means 알고리즘에 의해 초기 위치가 정해진 후, 파라미터 학습을 통해 최종 대표패턴으로 종합되어진다. 진동신호와 전류신호에 대해 상기의 과정이 각각 독립적으로 수행되고, 각 분류기로부터 얻어진 결과가 Dempster-Shafer 이론에 의해 결정레벨에서 융합되어진다.

Fig. 6과 7은 각각 전류신호와 진동신호를 이용한 결합 분류에 대한 테스트 결과를 나타낸다.

BBA  $m$ 은 분류 결과를 정량적으로 나타내며 0에서 1까지의 상대적인 크기를 가진다. 전류신호의 결과를 보면, 기계적 불평형(F2)과 베어링 결합(F6)의 크기가 다른 결함에 비해 상대적으로 낮은 값을 가지고 잘 분류되지 않음을 나타내며, 진동신호에서




Fig. 6 The BBA  $m$  of current signals




Fig. 7 The BBA  $m$  of vibration signals

Table 1 Experimental condition

Symbol	Fault condition
F1	Normal condition (without fault)
F2	Mechanical unbalance (15.64 g · cm)
F3	Broken rotor bar (12 EA)
F4	Bowed rotor (0.075 mm)
F5	Phase unbalance
F6	Faulty bearing (outer race fault)
F7	Angular misalignment (0.48 °)
F8	Parallel misalignment (0.1 mm)

**Table 2** Combination process of two classifiers about test data F2

진동 신호 결과	전류신호 분류결과								
	F1	F2	F3	F4	F5	F6	F7	F8	FOD
F1	.055	.16	0	.14	.20	.04	.22	.08	.10
F1 0	F1 0	∅ 0	∅ 0	∅ 0	∅ 0	∅ 0	∅ 0	∅ 0	F1 0
F2	.971	.05	.16	0	.14	.20	.04	.21	.07
F2 .971	∅ .05	F2 .16	∅ 0	∅ .14	∅ .20	∅ .04	∅ .21	∅ .07	F2 .099
F3	.006	∅	∅	F3	∅	∅	∅	∅	F3
F3 .006	∅ 0	∅ .001	F3 0	∅ 0	∅ .001	∅ 0	∅ .001	∅ 0	F3 0
F4	∅	∅	∅	F4	∅	∅	∅	∅	F4
F4 0	∅ 0	∅ 0	∅ 0	F4 0	∅ 0	∅ 0	∅ 0	∅ 0	F4 0
F5	∅	∅	∅	∅	F5	∅	∅	∅	F5
F5 0	∅ 0	∅ 0	∅ 0	∅ 0	F5 0	∅ 0	∅ 0	∅ 0	F5 0
F6	∅	∅	∅	∅	∅	F6	∅	∅	F6
F6 0	∅ 0	∅ 0	∅ 0	∅ 0	∅ 0	F6 0	∅ 0	∅ 0	F6 0
F7	∅	∅	∅	∅	∅	∅	F7	∅	F7
F7 .002	∅ 0	∅ 0	∅ 0	∅ 0	∅ 0	∅ 0	F7 0	∅ 0	F7 0
F8	∅	∅	∅	∅	∅	∅	∅	F8	F8
F8 .002	∅ 0	∅ 0	∅ 0	∅ 0	∅ 0	∅ 0	∅ 0	F8 0	F8 0
FOD	.042	F1	F2	F3	F4	F5	F6	F7	F8
FOD .042	.002	.007	0	.006	.008	.002	.009	.003	.004

**Table 3** Combined BBA  $m$  of two classifiers about test data F2

F2	Before normalization	∅	After normalization
F1	0.002	0.715	$0.002/(1(0.715)) = 0.007$
F2	0.263		$0.263/(1(0.715)) = 0.923$
F3	0		0
F4	0.006		$0.006/(1(0.715)) = 0.021$
F5	0.008		$0.008/(1(0.715)) = 0.028$
F6	0.002		$0.002/(1(0.715)) = 0.007$
F7	0.009		$0.009/(1(0.715)) = 0.032$
F8	0.003		$0.003/(1(0.715)) = 0.011$
FOD	0.004		$0.004/(1(0.715)) = 0.014$
Output	F2 > F7 > F5 > F4 > FOD > F8 > F1, F6 > F3		


는 편심 정렬불량(F7)과 편각 정렬불량(F8)이 서로 비슷한 크기를 가지고 있어 이 두 결함을 분류할 수 없음을 보인다.

#### 4.4 진단 결과의 결합

Table 2와 3은 데이터 융합의 예로 테스트 데이터 F2에 대한 전류신호와 진동신호를 이용한 분류결과를 Dempster-Shafer 결합규칙을 이용하여 결합하는 과정을 나타낸다. 두 분류기의 결과인 BBA  $m$ 은 테스트 데이터 F2의 결함분류에 대한 증거로써 고려되고, 각 분류기의 결합에서 공집합 ∅는 두 분류기의 믿음이 충돌을 일으키는 것을 의미한다. Dempster-Shafer 증거이론은 배타적 가설로 구성된 가설집합의 멱집합에 식 (3)과 (4)와 같이 믿음의 양을 0과 1사이의 값으로 할당하고 멱집합의 원소에 배정된 믿음의 합은 1을 만족해야 하며 공집합에 할당된 믿음 양은 0이 되어야 한다.

결합규칙에서는 이 조건이 만족되어야 하며, 이를 해결하기 위해서는 강제로 공집합의 BBA  $m$ 값을 0으로 만들고, 나머지 가설의 BBA  $m$ 값에 대해 공집합이 가졌던 BBA  $m$ 값에 비례하여 증폭시키는 의미에서  $1-m(\{\emptyset\})$ 으로 나누어 주어야 한다. 이 과정을 정규화라 하며, Table 3에 테스트 데이터 F2에 대한 두 분류기 결합의 정규화 전과 후의 결과를 나타내었다.

Fig. 8은 독립적으로 수행된 두 분류기의 진단결과를 결합하였을 때의 BBA  $m$  값을 보여주고 있다. 비록 진동신호만을 이용한 경우에 비해 F2와 F6의 결과가 상대적으로 약간 낮은 값을 가지지만, 전류신호만을 이용한 경우에 비해서는 모든 결과가 상대적으로



**Fig. 8** Final BBA  $m$  of current and vibration signals



로 매우 높은 BBA  $m$ 을 나타내고 있다. 이는 각각의 분류기에서 결합분류에 실패한 전류신호의 F2와 F6, 진동신호에서의 F7과 F8 결합이 두 분류 결과의 융합기법을 통하여 모든 결합을 성공적으로 분류할 수 있음을 나타낸다. 즉, 진동신호의 F7과 F8이 전류신호를 이용한 분류기에서는 서로 큰 차이를 가지고 분류되는 두 분류기의 상호 보완적인 특성때문에 이러한 특성을 결합한 최종 결과에서는 각각의 결합에 높은 BBA  $m$  값을 가지며 모두 양호하게 분류되는 것을 알 수 있다.

## 5. 결 론

이 연구에서는 산업용 구동기로서 가장 널리 사용되고 있는 유도전동기의 결합진단 정도의 향상을 위해, Dempster-Shafer 증거이론, 데이터 융합기법 및 신경망 알고리즘을 적용한 결합진단기법을 새로이 제안하였다. 그리고 진단 성능을 검토하기 위해 각종 결합을 재현할 수 있는 결합 시뮬레이션 실험장치를 이용하여 각종 결합조건에 따른 진동 및 고정자 전류신호를 취득하고, 이를 이용하여 특징을 추출하였다. 이들 데이터를 이용하여 신경망 분류기를 학습하고 미학습 신호의 데이터를 이용하여 분류성능을 조사하였다. 진동 또는 전류신호 데이터를 독립적으로 이용한 분류결과는 일부 결합을 정확히 분류할 수 없었으나, 이들 결과의 융합을 통하여 모든 결합조건을 올바르게 분류할 수 있음을 확인하였다. 신경망의 분류 문제는 입력패턴과 참조(reference)패턴 집합과의 유사성에 바탕을 두고 있고, 이 논문에서는 이러한 정보가 기본신뢰배정값(BBA  $m$ )으로 주어져 정량적으로 평가되고 Dempster-Shafer 이론으로 결합됨으로써 각각의 분류기의 결과가 상호보완적으로 작용하기 때문에 각각의 분류기보다 진단의 정확성을 높일 수 있다.

## 참 고 문 헌

(1) Singh, G.K. and Kazzaz, S.A.S.A., 2003, "Induction Machine Drive Condition Monitoring and Diagnostic Research- A Survey," Electric

Power Systems Research, Vol. 64, pp. 145~158.

(2) Bonnett, A.H., 2000, "Root Cause AC Motor Failure Analysis with a Focus on Shaft Failures," IEEE Trans. on Industry Application, Vol. 36, No. 5, pp. 1435~1448.

(3) 양보석, 2003, 유도전동기의 고장원인분석 및 진단기술, 한국소음진동공학회, 제 2회 설비진단기술강습회, pp. 62~104.

(4) Yang, B.S., Jeong, S.K., Oh, Y.M. and Tan, A.C.C., 2004, "Case-Based Reasoning System with Petri Nets for Induction Motor Fault Diagnosis," Expert Systems with Applications, Vol. 27, No. 5, pp. 301~311.

(5) ISO, 교류전동기의 포괄적인 On-line 감시도구, ISO/WD 19035-2.

(6) Benbouzid, M.E.H., 2000, "A Review of Induction Motors Signature Analysis as a Medium for Faults Detection," IEEE Trans. Industry Electronics, Vol. 47 pp. 984~993.

(7) Manyika, J. and Durrant-White, H., 1994, Data Fusion and Sensor Management, Ellis Horwood.

(8) 김진형 외 4명, 1998, 인공지능 이론 및 실제, 사이텍미디어.

(9) Hall, L.D. and Llinas, J., 1997, "An Introduction to Multisensor Data Fusion," Proc. IEEE, Vol. 85, No. 1, pp. 6~23.

(10) Lefevre, E. and Vannoorenberghe C.O., 2002, "Belief Function Combination and Conflict Management," Information Fusion, Vol. 3, pp. 149~162.

(11) Denoeux, T., 2000, "A Neural Network Classifier Based on Dempster-Shafer Theory, IEEE Trans. System, Man, Cybern. A: System and Humans, Vol. 30, No. 2.

(12) Denoeux, T., 1995, "A k-nearest Neighbor Classification Rule Based on Dempster-Shafer Theory," IEEE Trans. System, Man, Cybern., Vol. 25, pp. 804~813.

(13) Dempster, A.P., 1967, "Upper and Lower

Probabilities Induced by Multivalued Mappings," *Annals of Mathematical Statistics*, Vol. 38, pp. 325~339.

(14) Shafer, G., 1976, *A Mathematical Theory of Evidence*, Princeton University Press, Princeton.

(15) Smets, P. and Kennes, R., 1994, "The Transfer-able Belief Model," *Artificial Intelligence*, Vol. 66, pp. 191~243.

(16) Yang, B.S., Kim, K. and Rao, R.B.K.N.,

2002, "Condition Classification of Reciprocating Compressors using Radial Basis Function Neural Network," *Int. Journal of COMADEM*, Vol. 5, No. 4, pp. 12~20.

(17) Yang, B.S., Han, T. and Kim, Y.S., 2004, "Integration of ART-Kohonen Neural Network and Case-Based Reasoning for Intelligent Fault Diagnosis," *Expert System with Application*, Vol. 26, pp. 387~395.