

데이터 융합과 Dempster-Shafer 이론을 이용한 유도전동기의 결합진단

Application of data fusion and Dempster-Shafer theory in fault diagnosis of induction motors

김광진* · 한 천** · 양보석***

Kwang Jin Kim, Tian Han and Bo-Suk Yang

Key Words : Dempster-Shafer Theory(덴스터-셰이퍼 이론), Data Fusion(데이터 융합), Feature Extraction(특징추출), Neural Network(신경망), Fault Diagnosis(결합진단), Electric Motors(전동기)

ABSTRACT

The technology of machine condition monitoring is used effectively to detect the machine faults at an early stage using different machine quantities, such as current, voltage, temperature and vibration. Induction motors are most widely used to drive pumps, compressors and fans in industrial drives. This paper presents approach to data fusion using Dempster-Shafer theory because only one technique has uncertainty. So we can obtain advanced accuracy of the machine fault diagnosis. Vibration and current quantities are applied to diagnose three-phase induction motor.

1. 서론

산업현장에는 설치의 간편함과 운전 신뢰성 때문에 펌프, 압축기, 팬 등의 구동 장치로서 유도전동기가 널리 사용되고 있다. 비록 유도전동기가 높은 신뢰성을 가지고 있다 하더라도 기계적 문제와 전동기 내부에 작용하는 전기적 문제의 조합으로 인해 여러 고장모드의 결합이 발생하게 되고 전동기에 전기 및 기계적 결합이 발생하면 기계의 수명, 제품의 품질과 성능을 저하시키게 된다. 회전기계에서 발생하는 결합을 진단하는 주요 방법 중에 하나가 고장발생으로 야기된 진동과 전류신호를 측정하는 것이다. 신호처리기술을 이용하여 파괴적인 고장에 이르기 이전에 진동분석으로 중요한 정보를 획득하는 것이 가능하다.

결합 진단을 수행하는데 있어서 센서는 인식(sensing) 대상에 대한 정보량을 측정하기 위해 사용된다. 이러한 경우, 대상의 상태는 어떠한 양이나 변수 또는 매개변수로 취급하게 되고 인식의 관심이 된다. 측정된 양과 대상 사이에 관계나 사상(mapping)이 존재할 때, 특별한 센서가 고려되어진다. 이런 관점에서, 센서의 물리적 설명은 매우 유용하다. 하지만 그런 설명이나 물리적 모델은 센서의 작동을 지배하는 원리와 측정된 결과의

기호설명

- Ω 분별프레임(FOD; frame of discernment)
- m 기본신뢰배정값(basic belief assignment)
- \oplus 정규화 결합(normalized rule of combination)
- \cap unnormalized or conjunctive rule
- \otimes 증거체 간의 정규화 결합
- \mathbf{x} 입력벡터
- \mathbf{p}^i 대표 패턴(prototypes)
- d^i 입력벡터와 대표 패턴의 유클리드거리
- ω 클래스
- α^i, γ^i 대표 패턴과 관련된 파라미터
- u_q^i 대표 패턴의 클래스 멤버십
- ϕ^i d^i, γ^i 에 따른 감소지수함수
- s^i 활성화함수(activation)
- $E_v(\mathbf{x})$ 입력벡터 \mathbf{x} 의 출력오차
- L_i 인공신경망에서의 층(layer)

* 부경대학교 대학원
E-mail : hugkj@mail1.pknu.ac.kr
Tel : (051) 625-1604, Fax : (051) 623-1405

** 부경대학교 대학원

*** 부경대학교 기계공학부

완전한 이해의 부족으로 근사값(approximation)일 수 있다. 이것은 종종 불완전한 지식과 대상 시스템의 이해 부족 및 센서와의 상호작용에 의해 혼란해진다. 그리고, 센서 측정치는 원래 불확실성의 다른 정도를 구체화하고, 종종 거짓이거나 잘못된 것일 수 있다. 측정 장비의 물리적, 공간적 한계로 종종 단일 센서에 의해 부분적인 정보만을 제공하게 된다. 이러한 단점들은 하나의 센서로는 제품 성능과 대상 환경에 대한 일관된 설명을 제한하는 단점을 가지게 된다. 또한, 하나의 센서로부터 가능한 많은 정보를 추출하는 센서기술, 수많은 계산 방법 및 알고리즘의 발전에도 불구하고 어떠한 하나의 센서에서도 때로는 제 각각이고 동적인 환경에서 필요한 정보를 신뢰할 수 있게 취득할 수 없는 문제점도 존재한다.⁽¹⁾

본 논문에서는 유도전동기의 결함 진단에 대한 진단 신뢰성을 향상시키기 위해, 전동기에서 진동 신호와 전류신호를 취득하여 그 특징들을 추출한다. 그리고 이들 특징에 대해 증거이론의 하나인 Dempster-Shafer 이론을 적용한 신경망(neural network)을 이용하여 상태분류 결과를 정량적으로 평가하고, 두 신호의 분류결과를 결합해서 향상된 진단 정확도를 얻는 진단 알고리즘을 제안한다. 그리고 실제 유도전동기의 결함에 적용하여 그 유용성을 비교, 검토한다.

2. 이론적 배경

2.1 데이터 융합⁽²⁾

최근 다중센서(multi-sensor)의 데이터 융합(data fusion) 기술은 민간, 군사부문의 응용을 위해 지대한 주목을 받고 있다. 데이터 융합기술은 다중센서와 연관된 데이터 베이스로부터 데이터를 결합하는 기술이다. 그리하면 하나의 센서를 사용하는 것보다 향상된 정확성과 더 많은 특별한 추론(inferences)을 이끌어낼 수 있다.

여러 가지 소스(sources)로부터 취득된 정보들을 결합하는 데는 여러 문제점들이 발생할 수 있다. 특히 다른 센서로부터 제공된 정보들을 결합하는 경우, 여러 소스가 관심 데이터에 대한 정확하거나 부정확 또는 불확실한 정보를 제공하는 다중 소스정보시스템 및 중합되는 수치적 파라미터에 대한 전문가 개인마다 다른 설명을 나타내는 분야에서 정보의 경쟁(conflicting)이라는 문제가 발생하게 된다.

정보가 조잡하고 부족하며 정확성이 결여된 상황에서 확률적 모델에 바탕을 둔 데이터 융합 방

법은 문제를 처리하는데 항상 만족할 수 없으며 유용한 정보의 특성에 근거해서 정보를 표현하기 위한 여러 가지 모델이 사용될 수 있다. 확률이론과 증거이론(evidence theory)에 근거한 믿음함수(belief function) 그리고 upper 및 lower probability와 같은 정량적인 모델과 가능성(possibility)이론, 비단조(non-monotonic) 추론과 같은 정성적 모델이 있다.

2.2 Dempster-Shafer 이론⁽³⁻⁵⁾

증거이론은 lower 및 upper 확률분포에 관한 Dempster의 연구에 기초하고 있다. 불확실한 지식을 모델링하기 위한 믿음함수의 유용성이 Shafer에 의해서 연구되었다. 증거이론은 먼저 분별 프레임(FOD; Frame Of Discernment)이라 일컬어지는 가설집합 Ω 를 제안한다.

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

이는 상호배타적(exclusive)이고 전역적인(exhaustive) N 개의 가정으로 구성되어 있다. 분별프레임으로부터 2^N 개의 명제로 구성된 멱집합 2^Ω 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 것은 기본신뢰배정함수(BAA; Basic Belief Assignment)로써 식 (3)과 같이 Ω 의 멱집합 2^Ω 에 $[0, 1]$ 의 값을 사상하는 함수 m 으로 주어지고 식 (4)와 같은 특징을 갖는다.

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

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

Ω 의 원소에 배정된 믿음의 크기(mass)는 확률분포와 유사하지만 단위 크기(unit mass)가 2^Ω 의 원소에 분배된다는 사실이다. 즉, Ω 내의 한 원소집합(singleton) 뿐만 아니라 복합가설(composite hypothesis)에도 분배되는 것이다. $m_j(A) > 0$ 인 전체집합 Ω 의 부분집합 A 를 m 의 관심원소(focal element)라 한다. m 과 관련하여 믿음함수(belief function) $Bel(A)$ 와 개연성함수(plausibility function) $Pl(A)$ 를 다음과 같이 정의한다.

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

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

$Bel_j(A)$ 는 가설 A 가 진실임을 나타내는 믿음의 전체적인 척도로써 판단될 수 있다. $Pl_j(A)$ 는

유용한 추가적인 정보가 제공되어지면 잠재적으로 A 에 할당될 수 있는 믿음의 크기를 나타낸다.

정보소스(information source)인 S_j 로부터 제공된 BBA m_j 는 결합법칙에 의해 각 소스의 지식을 종합하여 결합된 크기를 제공한다. 믿음의 크기(Belief masses)는 각 소스로부터 주어진 믿음함수에 내포되어있는 전체 지식을 이용하여 결정짓기 과정에 이용될 수 있다. 2개의 독립적인 증거체로부터 도출된 BBA's m_1 과 m_2 는 직교합(orthogonal sum)이라 불리는 Dempster의 결합법칙(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 Ω 의 부분집합 B 와 C 가 존재해야 한다는 것이다. 즉, $m_1(B) \neq 0$ 과 $m_2(C) \neq 0$ 조건이 필요하다. 이런 경우, m_1 과 m_2 는 combinable 하다고 한다. 이와 달리, Smets는 unnormalized 또는 conjunctive 결합법칙 \cap 를 제안하였고, 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)을 위반하게 된다. 그래서 unnormalized 법칙을 이용하는 경우에 믿음함수의 정의는 식 (10)과 같이 정의된다.

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

공집합에 할당되는 BBA $m(\emptyset)$ 는 식(11)과 같이 정의된다.

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

식 (8)과 식 (11)에서 $m(\emptyset)$ 의 크기는 두 정보소스 S_1 과 S_2 사이의 경쟁(conflict)을 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 Ω 에서 하나의 가설을 선택하는 결정짓기에 대한 문제는 믿음함수와 개연성함수가 하나의 가설에 대해서 다른 순위(rank)를 유도하기 때문에 발생한다. 즉, Ω 의 부분집합 A 와 B 에

대해서 $Bel(A) < Bel(B)$ 인 반면 $Pl(A) > Pl(B)$ 이 가능하기 때문이다. 이런 이유로 해서 믿음함수는 결정짓기에 있어서 확률함수로 변하게 된다. 모든 $A \subseteq \Omega$ 에 대한 A 의 원소에 $m(A)$ 의 BBA를 동등하게 분배하는 Pignistic 변환이 Smets⁽⁷⁾에 의해 제안되었고 식 (12)로 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. 본 논문에서는 Denoeux의 모델을 이용하게 되고 2.3 절에 알고리즘을 소개한다.

2.3 분류화 알고리즘⁽⁴⁾

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 증거로서 고려하게 된다. 이 증거는 분별프레임 $\Omega = \{\omega_1, \dots, \omega_M\}$ 에 대해서 BBA \mathbf{m}^i 로 표현되어진다. \mathbf{x}^i 가 클래스 ω_q 에 소속되면 unit mass가 Ω 의 두 부분집합 즉, $\{\omega_q\}$ 와 Ω 자체에 분배되어진다. 훈련집합 내에서 최근접(nearest neighbors; NN) 탐색의 계산 복잡성(complexity)이 k -NN⁽⁵⁾법의 단점으로 알려져 있다. 이러한 문제점은 제한된 수의 대표패턴(representative patterns) 또는 prototypes의 형태로 훈련집합을 종합함으로써 경감된다. 클래스에 패턴할당은 n 개의 prototypes: $\mathbf{p}^1, \dots, \mathbf{p}^n$ 과의 거리를 계산함으로써 구해진다. 각각의 prototypes i 는 개개의 클래스 ω_q 에 소속도(membership) u_q^i , ($\sum_{q=1}^M u_q^i = 1$)를 가진다. 특별한 경우, 클래스 q 에 prototypes의 소속도 $u_q^i = 1$ 할당된다 ($l \neq q$ 에 대해서 $u_l^i = 0$).

\mathbf{x} 의 클래스 소속도에 관한 불확실성을 나타내는 BBA는 아래의 3 단계로 계산되어진다.

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

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

Step 2: 각각의 prototype에 의해서 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 아래의 식으로 계산된다.

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

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

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

ϕ^i 는 0과 1사이의 값을 갖는 감소함수이고, α^i 는 prototype i 와 관련된 파라미터 이며 $0 < \alpha^i < 1$,

γ^i 또한 prototype i 와 관련된 양의 값을 갖는 파라미터이다. 각각의 prototype 의 클래스 소속도 $u_q^i > 0$ 인 클래스 ω_q 에 양의 mass 가 할당되고 식 (17)과 식 (18)을 만족하는 식으로 구성된다.

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

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

Step 3: n 개의 BBA's $m^i, i = 1, \dots, n$ 는 conjunctive 법칙 또는 Dempster 의 법칙에 의해서 결합되어진다. 전자는 unnormalized BBA $m = \bigcap_{i=1}^n m^i$ 후자는 normalized BBA:

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

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

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

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




Fig. 1 Connectionist implementation of the evidence-theoretic classifier

분류화 알고리즘은 Fig.1 과 같이 1 개의 입력층 (input layer)과 L_1, L_2 2 개의 은닉층(hidden layer) 그리고 출력층(output layer) L_3 로 연결된 RBF 인공 신경망의 형태로 구성되어 있다.⁽⁶⁾ L_1 에서 L_2 까지의 각 층은 앞의 **Step 1** 부터 **Step 2** 의 과정을 표현한 것이다.

(1) 은닉층 L_1 은 $i=1, \dots, n$ 에 대해서 활성화함수 $s^i = \alpha^i \exp\{-\gamma^i (d^i)^2\}$ 의 n 개 units 를 포함하고 있다. 훈련집합으로부터 prototypes \mathbf{p}^i, α^i 및 γ^i 의 벡터가 구성되고 테스트 데이터가 입력되면 s^i 의 값을 계산하게 된다.

(2) 은닉층 L_2 는 각 prototypes 과 관련된 BBA m^i 를 계산한다. 전체집합 Ω 와 Ω 내의 클래스 $\omega_q, q=1, \dots, M$ 에 대해서 $M+1$ units 의 n 개의 module

로 구성되어 있다. Module i 는 이전층의 뉴런 i 와 연결되어 있고, 클래스 ω_q 와 관련된 prototypes 의 소속도 u_q^i 로부터 belief mass 에 해당하는 $\mathbf{m}^i = (m_1^i, \dots, m_{M+1}^i)'$ 를 계산하게 된다.

$$\mathbf{m}^i = (m^i(\{\omega_1\}), \dots, m^i(\{\omega_M\}), m^i(\Omega))' \quad (22)$$

$$= (u_1^i s^i, \dots, u_M^i s^i, 1 - s^i)' \quad (23)$$




Fig. 2 Details of incoming connections to module i of layer L_3

(3) n 개의 BBA's $m^i, i = 1, \dots, n$ 는 $M+1$ sigma-pi units 의 n modules 로 구성된 출력층 L_3 에서 계산되어진다. 모듈 i 의 활성벡터 $\bar{\mu}^i = (\mu_1^i, \dots, \mu_{M+1}^i)'$ 는 식 (24)와 같이 정의된다.

$$\bar{\mu}^i = (\mu^i(\{\omega_1\}), \dots, \mu^i(\{\omega_M\}), \mu^i(\Omega))' \quad (24)$$

μ^i 는 BBA's m^1, \dots, m^i 의 conjunctive 결합이다.

$$\mu^i = m^i \quad (25)$$

$$\mu^i = \bigcap_{k=1}^i m^k = \mu^{i-1} \cap m^i \quad i = 2, \dots, n \quad (26)$$

Fig. 2 와 같이 L_3 내에서는 모듈 $i-1$ 와 L_2 의 모듈 i 로부터 입력이 있으면 L_3 의 $i > 1$ 인 모듈의 각각의 요소를 계산하는 것이다. 즉, $i = 2, \dots, n$ 에 대한 활성벡터 $\bar{\mu}^i$ 는 아래의 공식으로 반복적으로 (recursively) 계산되어진다.

$$\mu_j^i = \mu_j^{i-1} m_j^i + \mu_{j-1}^{i-1} m_{M+1}^i + \mu_{M+1}^{i-1} m_j^i \quad j = 1, \dots, M \quad (27)$$

$$\mu_{M+1}^i = \mu_{M+1}^{i-1} m_{M+1}^i \quad (28)$$

(4) 위의 절차를 통해 네트워크의 출력벡터 $\mathbf{m} = (m_1, \dots, m_{M+1})'$ 는 다음과 같이 정의된다.

$$\mathbf{m} = \mu^n \quad (29)$$

$$\mathbf{m}' = \mathbf{m} / K, \quad K = \sum_{k=1}^{M+1} mk \quad (30)$$

2.4 파라미터 학습

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

$$P_{v,q} = m_q + vm_{M+1} \quad q = 1, \dots, M \quad (31)$$

$$0 \leq v \leq 1$$

$P_{0,q}$, $P_{1,q}$ 그리고 $p P_{1/M,q}$ 는 BBA m 에 대해서 각각 클래스 ω_q 의 믿음, 개연성 그리고 pignistic 확률을 나타낸다. 주어진 v 와 입력패턴 \mathbf{x} 의 출력오차 $E_v(\mathbf{x})$ 는 식 (32)로 정의된다.

$$E_v(\mathbf{x}) = \frac{1}{2} \|\mathbf{P}_v - \mathbf{t}\|^2 = \frac{1}{2} \sum_{q=1}^M (P_{v,q} - t_q)^2 \quad (32)$$

크기 N 의 전체 훈련집합 \mathbf{x} 의 평균출력오차는 식 (33)으로 정의되고 오차를 최소화하는 파라미터 학습을 하게 된다.

$$E_v = \frac{1}{N} \sum_{\mathbf{x} \in X} E_v(\mathbf{x}) \quad (33)$$

정규화된(normalized) 출력벡터 \mathbf{m}' 를 이용한다면 이에 상응하는 변형된 출력벡터 \mathbf{P}'_v 와 E'_v 는 같은 방식으로 정의되어진다.

파라미터 p'_k , γ^i , α^i 및 μ^i_j 는 식 (34)의 구속조건 하에 E_v 또는 E'_v 를 최소화 시키기 위해서 조절되어질 수 있다.

$$\gamma^i > 0, \quad 0 < \alpha^i < 1, \quad \sum_{j=1}^M \mu^i_j = 1, \quad 1 \leq i \leq n \quad (34)$$

3. 실험 및 테스트결과

본 논문에서는 유도전동기의 동적 특성들을 관찰하고 상태를 파악하며 결함을 찾아내기 위해서 진동신호와 전류신호를 사용하였다. 유도전동기의 결함을 분류하기 위해서 다음의 과정이 수행되었다. 먼저 데이터를 취득한 후에 특징추출을 하게 되고 추출된 특징들 중에 각각의 결함을 분류하기에 용이한 특징 선별과정을 거치고 선별된 특징들

로부터 데이터를 훈련시키게 되고 최종적으로 결함분류를 수행하는 순서이다.

3.1 데이터 취득

유도전동기의 결함분류를 테스트하고 확인하기 위하여 Fig. 3 과 같이 실험장치를 구성하였다.




Fig. 3 Experimental apparatus

베어링 하우징의 축방향, 수평방향 및 수직방향으로 가속도 센서를 부착시키고 3 상 전원공급 리드선에 3 개의 클램프 전류계를 연결하였다.

Table 1 Experimental conditions

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

Table 1 에 설명된 8 가지 결함에 대해서 실험을 수행하였다. 최대 주파수는 3 kHz 로 설정하고 샘플링 개수는 16384 개로 하였다. 각각의 결함조건에 대해서 20 개의 시간신호를 취득하여 총 160 개의 데이터를 취득하였다.

3.2 특징 추출

본 논문에서는 특징추출을 수행하기 위해서 측정된 신호의 시간영역 데이터와 주파수영역의 데이터에 대해서 통계적 방법이 이용되었다. 가속도 신호에 대해서는 수평방향의 센서로부터 시간영역 신호의 실효치(RMS), 첨도(kurtosis) 및 entropy

estimation 을, 전류신호에 대해서는 RMS, entropy estimation 및 주파수 영역의 RVF(Root Variable Square)값을 선택하였다. 적절한 전처리 후에 진동신호와 전류신호에 대해서 3 가지의 특징추출기법을 사용하여 각각에 대해서 3 차원으로 구성된 특징 공간을 구성하게 된다.

3.3 진단 결과

3.1 절에서 각각의 8 가지 결합조건에 대해서 취득된 20 개의 데이터 중 15 개는 훈련데이터로, 5 개는 테스트 데이터로 사용되었다. 이렇게 해서 총 120 개의 훈련데이터와 40 개의 테스트 데이터를 얻게 된다. 하나의 데이터는 3.2 절의 특징추출을 거쳐 3 차원 벡터로 되고 120 개의 데이터는 2.3 절에서 설명한 3 차원 prototypes 을 구성하게 된다. 이들 데이터는 k-means 알고리즘에 의해 초기 위치가 정해진 후 파라미터 학습을 통해 최종 prototypes 으로 종합되어진다. 진동과 전류 신호의 두 개의 독립적인 센서로부터 상기의 과정이 수행되고 각각의 분류기로부터의 결과를 Dempster-Shafer 법칙으로 결합되어진다.




Fig. 4 The BBA m of current signals




Fig. 5 The BBA m of vibration signals

Fig. 4 와 5 는 각각 전류신호와 진동신호의 결합분류 테스트 결과를 나타낸다. BBA m 은 분류 결과를 정량적으로 나타내며 0 에서 1 까지의 상대적인 크기를 가진다. 전류신호의 결과를 보면 기계적 불평형(F2)과 결합베어링(F6)의 크기가 다른 몇 가지 결합에 비해 상대적으로 낮은 값을 가지며, 진동신호에서는 편심 정렬불량(F7)과 편각 정렬불량(F8)이 비슷한 크기를 가진다.




Fig. 6 Final BBA m of current and vibration signals

Fig. 6 은 두 분류기의 결과를 결합하였을 때의 BBA m 값을 보여주고 있다. 비록 전류신호에서 F2 와 F6 가 상대적으로 낮은 값을 가지지만, 진동신호에서 다른 결합에 비해 높은 BBA m 을 보유하고 진동신호에서의 F7 과 F8 이 전류신호의 분류기에서는 높은 값을 가지는 상호보완적인 특성으로 최종적으로 각각의 결합에 높은 BBA m 값을 가지며 양호하게 분류되는 것을 볼 수 있다.

4. 결론

인공신경망에서 분류의 문제는 입력패턴과 참조(reference)패턴 집합과의 유사성에 바탕을 두고 있다. 본 논문에서는 이러한 정보가 기본신뢰배정(BBA m)으로 주어져 정량적으로 평가되어지고 Dempster-Shafer 이론으로 결합되어진다. 3 상 유도전동기의 동적특성을 얻고 결합진단의 정확성을 향상시키기 위하여 진동과 전류 파라미터를 이용하였고 8 가지 결합조건에 대해서 각각의 분류기의 결과가 상호보완적이기 때문에 진단의 정확성을 높일 수 있었다.

참고문헌

- (1) J. Manyika and H. Durrant-White, 1994, Data Fusion and Sensor Management, Ellis Horwood,
- (2) L.D. Hall and J. Llinas, 1997, An Introduction to

- Multisensor Data Fusion, *Proc. IEEE*, 85(1), 6-23.
- (3) E. Lefevre, O. Colot and Vannoorenberghe, 2002, Belief function combination and conflict management, *Information Fusion*, 3, 149-162.
 - (4) T. Denoeux, A neural network classifier based on Dempster-Shafer theory, 2000, *IEEE Trans. Syst., Man, Cybern. A: System and Humans*, 30(2).
 - (5) T. Denoeux, 1995, A k-nearest neighbor classification rule based on Dempster-Shafer theory, *IEEE Trans. Syst., Man, Cybern.*, 25, 804-813.
 - (6) B.S. Yang, K. Kim and Raj B.K.N. Rao, 2002, Condition Classification of Reciprocating Compressors using Radial Basis Function Neural Network, *International Journal of COMADEM*, 5(4), 12-20.
 - (7) P. Smets and R. Kennes, The transferable belief model, 1994, *Artificial Intelligence*, 66, 191-243.