

# 클러스터링과 Fuzzy Fault Tree를 이용한 유도전동기 고장 검출과 진단에 관한 연구

## A Study on Fault Detection and Diagnosis of Induction Motor by Clustering and Fuzzy Fault Tree

이성환, 신현익, 강신준, 우천희, 우광방

(Sung Hwan Lee, Hyun Ick Shin, Sin Jun Kang, Chun Hee Woo and Kwang Bang Woo)

**Abstract** : In this paper, an algorithm of fault detection and diagnosis during operation of induction motors under the condition of various loads and rates is investigated. For this purpose, the spectrum pattern of input currents is used in monitoring the state of induction motors, and by clustering the spectrum pattern of input currents, the newly occurrence of spectrum patterns caused by faults are detected. For the diagnosis of the fault detected, a fuzzy fault tree is designed, and the fuzzy relation equation representing the relation between an induction motor fault and each fault type, is solved. The solution of the fuzzy relation equation shows the possibility of occurrence of each fault. The results obtained are summarized as follows : (1) Using clustering algorithm by unsupervised learning, an on-line fault detection method unaffected by the characteristics of loads and rates is implemented, and the degree of dependency for experts during fault detection is reduced. (2) With the fuzzy fault tree, the fault diagnosis process become systematic and expandable to the whole system, and the diagnosis for sub-systems can be made as an object-oriented module.

**Keywords** : induction motor, fault detection and diagnosis, clustering by unsupervised learning, fuzzy fault tree

### I. 서론

전동기는 전기에너지를 기계적 에너지로 변환하는 원동기로서, 전 분야에 걸쳐 널리 사용되고 있으며, 전체 전력 사용량의 많은 부분을 차지하고 있다. 특히, 유도전동기의 경우, 강건한 설계와 제조로 이미 산업 전반에서 널리 성공적으로 사용되고 있다. 그러나, 고장이 발생하였을 때, 이를 적시에 발견하지 못한 채 방치하는 경우, 유도전동기 뿐만 아니라 전력 계통의 마비까지도 야기할 수도 있으며, 전동기 고장에 대비하기 위한 여분의 설비를 준비해야 할 수도 있다. 이는 시스템의 전체적인 신뢰도를 떨어뜨리고, 복구를 위한 추가 인력, 재정 및 시간의 손실을 초래한다[1][2].

유도전동기에서 발생할 수 있는 주된 고장 유형을 살펴보면 회전자 권선 손상[3], 고정자 권선간 단락, 결상(phase loss), 상 불평형(phase unbalance)[4] 그리고 베어링 고장[5] 등을 들 수 있다. 이러한 고장들을 검출하기 위한 기존의 방법들을 살펴보면 Penman[1] 등이 고정자 권선간 단락을 Randy 등이 회전자 권선 손상[3]과 베어링 고장[5] 검출을 위한 방법들 제안하였으나, 이들은 특정 고장 유형에 대해서만 다루고 있으며, 고장 검출을 위해 유도전동기 파라미터 정보와 전문가의 도움에 크게 의존하고 있다. 물론 Randy[6] 등이 전문가 시스템에 근거하여 여러 가지 고장 유형들에 대한 포괄적 고장 검출을 제안하였으나, 이전 정상 운전 상태와의 비교를 통해 고장의 여부만을 판단했을 뿐, 고장 원인에 대한 진단을 다루고 있지 않다. 이는 전문가 시스템을 사용하였음에도 발생한 고장의 종류에 대한 진단이 없었던 것은, 검출의 민감도와 처리 속도의 향상을 위해 입력 데이터 중 고장과 연관이 있는 부분만을 선택하기 위해 전문가 시스템을 사용했을 뿐, 고장 유형 진단을 위해 사용되지 않았기 때문이다.

본 논문에서는 고장 여부의 판단을 포함한 고장 종류에 대한 진단을 다룬다. 고장 종류에 대한 진단은 고장 여부의 판단과 진단의 두 과정에 의해 수행된다. 고장 여부의 판단은 유도전동기 상태를 가장 민감하게 보여주는 입력 전류 파형을 비교사 클러스터링 알고리즘인 Dignet[7]을 이용하여 클러스터링 하여, 고장 발생과 함께 새로이 형성되는 클러스터를 관찰함으로써 이루어진다. 즉, 유도전동기의 정상 운전 상태에선 부하의 특성을 고려하더라도 나타날 수 있는 전류입력 파형의 형태의 종류는 한정되어 있다. 그러나, 고장이 발생한 경우 유도전동기 입력 전류의 파형이 이전에 관찰되지 않았던 형태로 발생되므로 클러스터링 과정에서 정상 운전상태에서 나타나는 클러스터 외의 새로운 클러스터가 발생한다.

고장 종류에 대한 진단은 유도전동기에 대한 fault tree에 의한 고장 해석에 근거하며, 이를 퍼지 논리를 이용하여 발생한 고장에 대한 원인을 규명하게 된다[8]. 즉, 유도전동기를 이루는 각 부분의 고장 가능성과 전체 전동기 고장 가능성의 관계를 규정짓는 fault tree를 구성한 후, 이로부터 발생할 수 있는 고장 유형과 전동기 각 부분들간 고장의 원인-결과 관계를 파악하여, 고장 유형과 각 부분들간을 연관지어주는 퍼지 관계식(fuzzy relation equation)의 해를 유도함으로써[8][9] 관찰된 증상들로부터 각 부분들의 고장 가능성을 얻게 된다.

### II. 유도전동기 고장 유형

전기 기기에서 발생할 수 있는 고장을 살펴보면, 크게 기계적 고장, 기계적 고장 또는 두 고장의 복합으로 볼 수 있다. 대부분의 고장은 기계적 압력이 가장 크게 작용하거나, 절연이 파괴되는 경우와 같은 천이 동작에서 발생하는 것이 보통이다. 고장이 발생한 경우, 그 증상은 크게 진동, 열, 자장의 변화의 형태로 나타나며, 이를 감지하기 위하여 진동 센서, 온도 센서, 코일 그리고 입력전류 등을 이용한다. 이중, 입력전류를 이용한 감지 방법은 전동기의 상태에 가장

민감하게 반응하며, 대형 전동기의 경우 기기와 계통의 보호를 위해 계전기를 장착하는 것이 일반적이어서, 전동기 상태를 모니터링하기 위해 계전기에 장착되는 변류기를 사용하여 별도의 하드웨어적 추가가 없이 소프트웨어의 첨가만으로 구현할 수 있다는 점에서 유리하다. 다음은 전동기 입력전류를 통해 검출할 수 있는 고장들이다.

1. 공극 이상(air-gap eccentricity)

공극 이상은 회전자 축이 편향된 경우, 회전자가 고정자 위치에 대하여 부정확하게 설치되었을 경우, 고정자 권선이 움직이는 경우 등에 발생하는 고장으로서 회전자의 기계적 위치에 따라 증상이 변화한다. 따라서, 만약 공극 이상이 클 경우에는 전자장에 의한 회전력 불평형이 발생하여 회전자-고정자간 마찰 그리고, 그것에 의한 고정자 권선과 회전자 권선의 손상을 가져올 수 있다. 이러한 경우, 고정자 전류에 다음과 같은 주파수 성분이 발생한다[6].

$$f_{ecc} = f_e \left[ 1 \pm m \left( \frac{1-s}{\frac{p}{2}} \right) \right] \quad (1)$$

여기서  $f_e$ 는 공급전원의 주파수,  $m = 1, 2, 3, \dots, s$ 는 단위 슬립(per unit slip) 그리고  $p$ 는 유도전동기 극의 개수이다.

2. 회전자 권선 손상

회전자 권선 손상의 가장 흔한 증상은 과다한 진동, 잡음 그리고 시동시 방전 불꽃이다. 그러나 이러한 증상들은 이미 고장이 충분히 진전되어 회전자의 여러 곳에서 권선의 손상이 발생한 경우이다. 회전자 권선 손상의 초기 증상을 알아보기 위해 먼저 회전자 권선 손상에 의해 생겨나는 회전자내 변화를 살펴보면 그림 1(a),(b)와 같다.




그림 1. 회전자 권선 손상시 회전자 전류의 변화.  
Fig. 1. Change in rotor currents with one broken bar.

그림 1(a),(b)는 단일하게 발생한 회전자 권선 손상의 위치에서 전류의 분포가 최대가 되는 경우, 회전자 내 전류의 분포가 어떻게 달라지는가를 보여주고 있다. 즉, 회전자 권선 내부에서 흘러야할 전류의 대부분이 인근의 두 회전자 권선으로 흐르고 있다. 이는 정상적인 회전자 권선에 반대 방향으로 흐르는 같은 크기의 전류가 중첩된 것으로 모델링 될 수 있다. 회전자 권선 손상에 의해 나타나는 이러한 현상은 회전자 전류에 의해 발생하는 자계의 비대칭을 초래하여 공극 이상을 유발한다. 이 때, 회전자 권선 손상에 의해 발생하는 주파수 성분은 다음과 같다[6].

$$f_{brb} = f_e \left[ k \left( \frac{1-s}{s} \right) \pm s \right] \quad (2)$$

여기서  $f_e$ 는 전원 주파수,  $\frac{2k}{p} = 1, 5, 7, 13, \dots$ 이다.

위 (2)에 의해 나타나는 고조파 성분들이 다른 공극 이상에 비하여 구별되는 점은 회전자 권선 손상의 경우가 전원

주파수 주변에서의 증상의 크기가 더 크고, 높은 주파수로 갈수록 다른 고장들은 회전자 권선 손상에 비해 빠르게 감소한다.

3. 베어링 고장

베어링 고장의 경우 정상적인 동작 조건에서부터 고장이 발생하는 경우엔 보통 미세한 베어링 볼이나 링 표면의 균열이나 흠집에서 시작된다. 일단 균열이 발생하면 흠집에 주기적으로 힘이 가해져서 급속히 확산, 진전되어 급기야 베어링 내에 파편조각이 발생하여 그 정도가 감지할 수 있는 정도가 된다. 고장 주파수는 베어링의 기계적 구조와 전동기의 회전속도에 의해 결정된다. 즉, 베어링의 기계적 치수가 아래의 그림 2와 같을 때, 베어링의 바깥쪽 링에 고장이 발생한 경우와 안쪽 링에 고장이 발생한 경우에 나타나는 주파수는 (3)-(6)으로부터 각각 구할 수 있다[5].




그림 2. 볼 베어링의 치수.  
Fig. 2. Ball bearing dimensions.

바깥쪽 링 고장

$$f_o = f_e \pm k \left\{ \frac{n}{2} f_r \left[ 1 - \frac{BD}{PD} \cos \beta \right] \right\} \quad (3)$$

안쪽 링 고장

$$f_i = f_e \pm k \left\{ \frac{n}{2} f_r \left[ 1 + \frac{BD}{PD} \cos \beta \right] \right\} \quad (4)$$

여기서  $f_e$ 는 공급전원의 주파수,  $k$ 는 양의 정수,  $n$ 은 베어링 볼(bearing ball)의 수이다. 대부분의 베어링은 6~12개의 볼을 가지며, 이 때,  $f_o$ 와  $f_i$ 는 다음과 같이 근사화될 수 있다

$$f_i = f_e \pm k (0.6 n f_r) \quad (5)$$


$$f_o = f_e \pm k (0.4 n f_r) \quad (6)$$

여기서  $f_r$ 은 전동기의 회전속도이다.

4. 상 불평형

보통 유도전동기에 인가되는 3상 선 전압은 각각 120°의 위상차를 가지며, 동일한 크기를 갖는다. 그러나, 상 불평형이 발생하는 경우 정상적인 고정자 전류의 상순과는 반대인 역상 전류가 발생한다. 이는 회전자의 속도와 크기는 같으나 반대 방향으로 회전하는 자계를 발생시킨다. 이로 인해 회전자에 발생하는 맴돌이 전류(eddy currents)의 주파수가 정상 운전 상태의 두배가 되고, 이는 회전자의 금속 표면에 과열과 손상을 준다.

절연되어 있는 3상 시스템에서 상 불평형이 발생한 경우, 가장 큰 전류가 흐르는 상의 전류값과 가장 작은 전류가 흐르는 상의 전류값간의 차이( $\Delta I$ )와 역상전류( $I_{nsc}$ )사이엔 밀접한 관련이 있다. 그림 3은 20%의 역상 전류가 흐르는 경우의 상 전류에 대한 벡터 해석으로서 A상에서의 정상 전류와 역상 전류간의 각을  $\alpha$ 라고 할 때,  $\alpha$ 가 30°인 경우를 보여주고 있다.



정상 전류 :  $I_{A1} = A상$   $I_{B1} = B상$   $I_{C1} = C상$   
 역상 전류 :  $I_{A2} = A상$   $I_{B2} = B상$   $I_{C2} = C상$

그림 3. 역상 전류 발생에 대한 벡터 해석.  
 Fig. 3. The analysis for occurrence of negative phase current.

이와 같은 각 상 전류들간의 크기의 차를 이용한 방법은 주파수의 변화에 관계없이 적용된다는 장점을 갖고 있다. 이러한 상 불평형의 가장 극단적인 형태는 결상(phase loss)이다.

**III. 유도전동기 고장검출과 고장 원인 진단**

**1. 유도전동기 고장 검출 및 진단 과정**

유도전동기 고장 검출과 고장 원인을 진단하기 위한 과정을 전체적으로 살펴보면 그림 4와 같다.

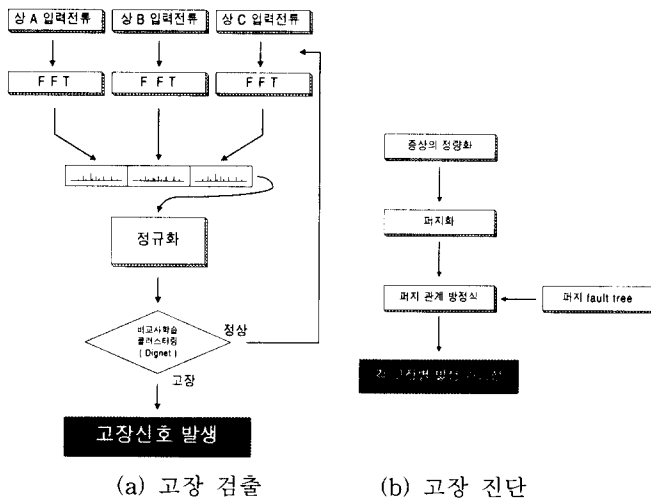


그림 4. 유도전동기 고장 검출 및 진단 과정.  
 Fig. 4. process for detecting and diagnosing induction motor fault.

**2. 입력 전류를 이용한 유도전동기 모니터링 및 고장검출**

앞서 설명한 고장의 유형들에 대한 설명에서와 같이 유도전동기 입력전류를 관찰하는 것이 유도전동기 상태를 모니터링하기 위한 가장 좋은 방법의 하나이다. 그러나, 유도전동기는 용량과 구조, 크기에 따라 종류가 다양하며, 종류가 같은 경우라도 사용 분야에 따라 작업 내용이 다르므로, 유도전동기에 유입되는 전류의 크기나, 패턴 또한 다양할 수밖에 없다. 유도전동기 상태를 좌우하는 이 모든 요소들을 항상 고려해야하는 것은 매우 번거로운 일이다. 특히, 베어링 고장과 회전자 파손의 경우와 같이 고장의 증상이 전동기의 회전 동작과 관련하여 발생하는 경우, 회전자 회전속도와 운전시 변화하는 부하특성에 따라 입력전류의 파형이 변화하는 것을 고려하여야 하며, 고장의 진전 속도가 매우 느리므로, 이의 검출을 위해선 전문가의 도움이 정기적으로 필요하다. 따라서, 전문가의 도움에 전적으로 의존하지

않는 유도전동기 고장 검출을 위해선, 유도전동기의 정상 상태 운전을 스스로 인식하여, 고장이 발생하였을 경우, 이를 구별할 수 있는 지능형 고장 검출이 필요하다. 지능형 고장 검출을 위해선 우선, 검출기가 정상 상태에 대한 인식능력을 갖고 있어야 한다. 그러나, 유도전동기 입력전류에 영향을 주는 전동기 부하특성은 전동기의 사용분야에 따라 천차만별이어서 그 특징을 단정지을 수 없다. 그러나, 전동기가 정상적으로 동작하는 경우 일정한 동작을 주기적으로 반복하는 경우가 일반적이므로, 부하의 특성은 알 수 없으나, 부하 특성에 의해 나타나는 전동기 입력 전류의 파형은 한정된 유형이 주기적으로 나타나는 것으로 생각할 수 있다. 즉, 유도전동기 입력전류에서 나타날 수 있는 파형 자체는 알 수 없으나, 그 종류가 한정되어 있다는 것이다. 따라서, 정상 운전 상태에선 입력 전류의 주파수 해석 결과를 클러스터링하면, 입력전류에 어느 정도의 외란이 포함된다 하더라도 비슷한 유형들로 이루어진 클러스터들이 한정된 개수로 생겨날 것이다[6]. 그러나, 몇 개의 클러스터가 생겨날 것이지는 유도전동기가 수행하게 될 작업 내용에 대한 정확한 정보가 없다는 것을 가정하였으므로 알 수 없다. 따라서, 주파수 해석결과를 자율적으로 클러스터링 해 줄 수 있는 알고리즘이 필요하다. 이러한 방법의 하나로 인공 신경망에 의한 비교사학습 클러스터링을 사용할 수 있다.

클러스터링은 유사한 유형을 갖는 데이터들은 묶어주는 것으로 대부분의 비교사 학습에 의한 클러스터링은 데이터가 갖고 있는 유형의 종류와 수에 대한 사전 지식이 없는 상태에서의 클러스터링을 의미한다. 따라서 클러스터링 알고리즘은 유사 정도에 대한 기준에 의한 데이터의 인식과 분류에 의존한다. K-means 알고리즘 또는 LVQ(Learning Vector Quantization) 알고리즘과 같은 전통적 클러스터링 알고리즘들은, 데이터가 속하게 되는 여러 개의 무리들, 즉 클러스터의 갯수에 대한 사전 지식을 필요로 한다는 점에서 진정한 의미의 비교사학습이라고 보기 어렵다. 그리고, Hopfield Net과 그로부터 유도된 인공 신경망에 의한 알고리즘들은 다른 클러스터로 인식되는 데이터들에 대해 서로 직교화되어야 한다는 제약을 갖고 있다.

이러한 의미에서 진정한 자기 구성 능력을 갖는 인공 신경망으로서 Carpenter와 Grossberg가 제안한 ART2를 들 수 있다[10]. ART2의 경우, vigilance 파라미터를 기준으로 하여 입력된 데이터가 어느 클러스터에 속하게 될 것인지를 결정한다. 그러나, vigilance 파라미터는 top-down 하중과 bottom-up 하중간의 유사정도로부터 해당 클러스터를 결정하기 위한 것일 뿐, 입력 데이터와 클러스터 중심간의 관계를 명확히 규정하지 못한다. 이러한 이유로 ART2를 이용한 클러스터링에서 vigilance 파라미터를 포함한 여러 파라미터들과 초기 값을 설정하는 것은 그 자체로서 기술이 될 정도이며, 데이터 의존도가 커서 일관되게 적용하기 어렵다. 뿐만 아니라, ART2는 입력 데이터의 유형에 관계없이 클러스터 입력 데이터의 개수에 의해 초기 값이 정해지므로, 연결하중들이 생성된 클러스터의 중심으로 수렴하는데 많은 학습 기간이 소요된다. 그러나, Dignet의 경우, 입력 데이터에 의해 새로운 클러스터가 생성되면, 새로운 입력 데이터 자신이 클러스터의 중심 벡터가 되어 일률화된 초기 값으로부터 수렴하기 위한 시간이 소요되지 않고, 클러스터 중심의 이동을 위한 학습과정이 반복에 의한 수렴이 아닌 한번의 연산에 의해 결정되므로 학습속도 또한 빠른 알고리즘으로서 Thomopoulos등이 제안한 Dignet을 이용하였다. Dignet의 구조에 대한 전체적 설명은 다음과 같다[7].

Dignet의 구성은 그림 5에서와 같다. 즉, 입력 데이터는

정규화과정을 거쳐, 입력의 크기에 영향받기 보다는 입력이 갖는 모양에 의해 특징이 결정되도록 한다. 정규화된 입력 데이터는 이미 생성되어 있는 클러스터들과의 유사 정도를 가늠하기 위하여 입력 데이터 벡터와 클러스터 중심 벡터들 간의 내적을 구하게 된다. 내적의 결과는, 클러스터의 영역을 지정하기 위해 사용자에게 의해 정해지는 신호대잡음비(signal to noise ratio)에 의한 문턱 값을 넘는 것과 그 미만의 것으로 분류된다. 문턱 값을 넘는 경우는 입력 데이터가 클러스터의 영역에 속한다는 것을 의미하는 것으로 이들 클러스터 중 가장 큰 내적 값을 갖는 클러스터의 중심에 가장 가까운 것으로 볼 수 있다. 따라서, 문턱 값을 넘는 클러스터들에서 가장 큰 값을 갖는 클러스터가 입력된 데이터를 자신의 클러스터의 원소로 갖게 되며, 나머지 문턱을 넘는 클러스터들은 경쟁에서 도태된 것으로 볼 수 있다. 경쟁에서 이긴 클러스터는 입력된 데이터 쪽으로 이동하게 되며, 진 클러스터는 입력 데이터로부터 먼 쪽으로 이동하게 된다. 이 때, 이동 거리는 클러스터 내의 원소의 개수에 의해 결정된다.

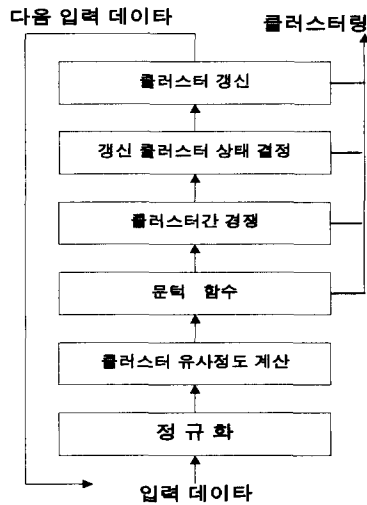


그림 5. Dignet의 기능도.  
Fig. 5. Function diagram in Dignet.

3. 고장 원인 진단

고장에 대한 원인을 진단하는 것은 이미 발생한 고장으로 부터의 신속한 복구를 위해서도 중요할 뿐 아니라, 시스템 운전에서의 주의와 향후 새로운 설계에서의 고려 측면에서도 중요하다. 고장이 발생했을 경우, 고장의 원인을 판단하는 것은 고장의 원인과 그 원인에 의해 나타나는 고장의 증상간의 연관성을 고려함으로써 가능하다. 즉 고장의 종류에 대한 관별이 필요하다.

고장이 발생하였을 경우 이는 곧 시스템의 특성이 비정상적으로 변화된 것으로, 앞서 비교사학습에 의한 클러스터링 알고리즘에서 살펴보았듯이, 기존의 정상상태에서 볼 수 없었던 새로운 데이터의 유형이 발생한 것으로 볼 수 있다. 이 때, 어떠한 고장이 발생하였는가를 알아보기 위한 방법으로 발생할 수 있는 고장들에서 나타나는 데이터의 유형과의 비교를 통한 방법을 들 수 있다. 즉 사전에 고장 유형별 고장 데이터 유형을 입수하여, 고장이 발생하였을 경우, 이들 고장 데이터 유형들과 비교를 행하는 것이다. 그러나, 이러한 클러스터링 과정에서 수행되는 방법을 사용함에 있어 주의해야 할 것은, 시스템의 특성이 저마다 다르고 환경의 변화에 따라 동적으로 변화할 뿐 아니라, 한 시점에서 발생

하는 고장이 단 한가지로 제한되지 않는 경우도 있다는 것이다. 즉, 두 가지 이상의 고장이 함께 발생되어 있는 상황에서 클러스터링 알고리즘을 사용하는 경우, 그 결과가 특정 고장이 단일하게 발생한 것으로 생각될 수 있다. 이는 클러스터링 알고리즘들이 경쟁에 의한 데이터 획득 과정에 근거하여 클러스터의 데이터 획득이 배타적이기 때문이다. 이의 보완을 위하여 fault tree에 근거한 진단 방법과 진단 해석을 위해 퍼지 논리를 사용할 수 있다.

3.1 fault tree

fault tree는 시스템에서 발생하게 되는 사고의 모델을 나타내며, 시스템 각 요소들의 고장과 관찰되는 증상간의 관계를 체계적으로 해석하기 위한 방법으로서 시스템의 각 부분간의 고장에 의한 연관성을 규정한다. fault tree를 이용하여 시스템 전체, 부-시스템 또는 각 요소들의 안정된 운전을 위한 신뢰도를 가늠할 수 있다.

fault tree를 이용하여 시스템의 신뢰도를 해석하는 전형적 방법을 순서화하면 다음과 같다.

1. 시스템의 각 부분들간에 상대적으로 원인이 되는 것들과, 결과가 되는 것들간의 인과관계를 조사하여, 이를 언어적 표현을 빌어 나타낸다.
2. 앞서 규정한 원인들과 결과들을 부울 대수의 형태(고장, 정상)로 나타낼 수 있도록 변형한다. 그 과정에서 가장 기본 고장(basic event), 유도 고장(induced event), 전체 고장(head event)의 단계를 구분한다.
3. 각 고장들을 부울 함수의 형태로 표현한다. 각각의 유도된 고장들은 서로 원인이 될 수 있으므로, 기본적인 고장, 유도된 고장, 전체 고장들간의 모든 부울 함수들은 시스템의 고장 모델을 이루기 위한 그래프를 형성하게 된다.
4. 각 기본적 고장들에 확률(빈도)를 할당하여 정성적 고장 모델이 첨가될 수 있다. 부울 대수와 확률 이론들을 이용하여 유도된 고장과 전체 고장에 대한 확률을 구할 수 있다.
5. 유도된 확률 값에 의한 시스템의 신뢰도를 제어한다.

위에서 살펴보았듯이 fault tree를 구성은 부울 대수의 표현을 빌어쓰게 되므로, 완성된 fault tree의 구조를 각종 논리 기호를 사용하여 나타낼 수 있다[11]. 주로 사용하게 되는 논리 소자는 논리곱, 논리합 그리고 부정이다.




그림 6. fault tree 모델.  
Fig. 6. fault tree model.

그림 6과 같은 구조를 갖는 간략한 fault tree에서 기본적 고장 A, B, C가 갖는 고장의 확률과 논리 소자로 표현된 고장과 증상간의 논리적 관계에 의하여 단계 Y에서 고장이 날 확률을 구할 수 있다. 즉, 단계 Y에서 고장이 발생할 확률 P<sub>Y</sub>는

$$P_Y = [1 - (1 - p_A)(1 - p_B)](1 - p_C) \quad (7)$$

으로 구할 수 있다. (7)은 다음과 같은 확률적 계산 방법에 의한다.

$$P_{AND} = \prod p_i \quad (i = 1 \dots n) \quad (8)$$

$$P_{OR} = 1 - \prod(1 - p_i) \quad (i=1 \dots n) \quad (9)$$

$$P_{NEG} = 1 - p \quad (10)$$

3.2 확률과 가능성

이와 같이 기존에 사용되어왔던 fault tree의 전형적 방법은 기본적 고장들에 대한 고장 확률로부터 시스템 전체의 고장 확률을 얻게 된다. 그러나, 이와 같이 확률을 이용하는 방법은 다음과 같은 문제점을 갖고 있다.

첫째, 모든 기본적 고장에 대한 확률의 값들을 아는 경우가 흔치 않다.

둘째, 실제의 시스템에서 고장이 발생하는 경우가 그리 흔치 않으므로, 관찰된 고장 발생의 빈도는 매우 넓은 분포를 갖는다. 뿐만 아니라 이전에 고장이 발생한 경우가 없는 경우도 있을 수 있다.

셋째, 과거 고장의 빈도로부터 기본적 사고에 대한 확률의 값을 구한다 하더라도, 시스템의 환경이 동적으로 변화하므로 과거의 운전 기록으로 정확한 확률을 구할 수 없다.

기본적 고장에 대한 부정확한 확률에 의해 발생하는 시스템 신뢰도 분석의 어려움을 덜기 위해 앞서 언급하였던 fault tree에 의한 시스템 신뢰도 해석 순서의 마지막 두 단계에 사고에 대한 상대적 빈도인 확률을 퍼지 수로 표현되는 가능성(possibility)으로 간주할 수 있다[12].

퍼지 수는 (11)의 조건을 만족시키는 그림 7에서 예를 든 것과 같은 정규화된 불룩한 멤버십 함수  $\mu(x)$ 의 연속된 실수 값의 집합이다.

$$\max \mu(x) = 1 \quad (x \in R) \quad (11)$$




그림 7. 멤버십 함수의 예.

Fig. 7. An example of membership function.

이상에서 살펴본 바와 같이, 시스템의 각 요소에 고장이 발생할 확률을 퍼지 수로 표현되는 고장 발생의 가능성을 사용하여 나타낼 수 있다. 퍼지 수에 의한 고장 발생의 가능성은 앞서 살펴보았던 비교사학습 클러스터링 방법에 의한 고장 검출 신호로부터 시스템 각 요소들 중 어느 것에서 고장이 발생하였는가를 fault tree에 근거하여 역으로 유추하게 된다. 이러한, fault tree에 근거한 고장의 진단은 고장 진단을 위한 체계적 방법을 제시할 뿐 아니라 시스템의 각 수준에서 관찰된 증상들이 갖는 불확실성을 고려할 수 있어 증상을 관찰함에 있어 시스템의 동적 특성에 크게 영향받지 않도록 할 수 있다. 따라서 (7)~(10)에서 사용된 확률에 의한 식 또한 퍼지 집합에서의 연산으로 바꾸어 생각한다.

3.3 퍼지 관계 방정식의 해를 이용한 고장 원인 분석

퍼지 고장 진단을 위한 첫번째 단계는 인과 행렬(causality matrix)를 구성하는 것이다. 인과 행렬은 증상들을 발생할 수 있는 고장 유형들에 대한 관계로 나타낸 것으로, fault tree의 기본적 고장들의 조합으로 구성된다. 이 인과 행렬과 고장 유형 행렬 그리고, 관찰된 증상의 행렬로 구성되는 인과 방정식(causality equation)의 해를 구함으로써, 관찰된 증상으로부터 각 고장 유형들의 고장 가능성을 얻게

된다. 이에 대한 자세한 설명은 다음과 같다[8].

$X = \{x\}$ 를 기본적 고장들의 집합,  $A = \{a\}$ 를 발생할 수 있는 모든 고장 유형들의 집합, 그리고  $B = \{b\}$ 를 관찰할 수 있는 증상들의 집합이라고 할 때, 인과 행렬  $R$ 은 다음과 같이 정의될 수 있다.

$$r_{ij} = 1 : \text{고장 유형 } a_i \text{가 증상 } b_j \text{를 일으키는 경우} \quad (12)$$

$$0 : \text{고장 유형 } a_i \text{가 증상 } b_j \text{를 일으키지 않는 경우}$$

위의 정의된 행렬을 이용하여 (13)과 같이 퍼지 논리를 이용하여 나타낼 수 있다.

$$b_i = \bigvee_j (r_{ij} \wedge a_j) \quad (13)$$

집합의 각 요소들간의 관계로 이루어진 위의 (13)은  $\circ$ -합성을 이용하여 위의 정의된 행렬에 의한 (14)와 같이 표현될 수 있다. 즉

$$b = a \circ R \quad (14)$$

위의 (14)는 고장 유형과 그 증상에 대한 관계를 나타내는 것으로 이를 인과 방정식이라 부른다. 이제, 인과 방정식의 해,  $a$ 를 구함으로써 각 고장 유형에 대한 고장 가능성을 얻어야 한다. (14)는 퍼지 집합  $a$ ,  $b$ 와 그들간의 관계를 규정하는 퍼지 관계  $R$ 에 의해 구성되는 퍼지 관계식과 같은 형태로서 이의 해는 Sugeno와 Pappis의 해법에 따른다[9]. 퍼지 관계 방정식의 해를 구함에 앞서 필요한 합성들과 집합의 정의에 대하여 살펴보면 다음과 같다.

$\alpha$ -합성 :  $x \alpha y$ 로 나타내는 스칼라 값  $x$ ,  $y$ 에 대한  $\alpha$ -합성은 다음과 같이 정의된다.

$$x \alpha y = 1 : \begin{matrix} x \geq y \\ y : x < y \end{matrix} \quad (15)$$

$\beta$ -합성 :  $x \beta y$ 로 나타내는 스칼라 값  $x$ ,  $y$ 에 대한  $\beta$ -합성은 다음과 같이 정의된다.

$$x \beta y = 0 : \begin{matrix} x < y \\ y : x \geq y \end{matrix} \quad (16)$$

$\Phi$ -집합 : 주어진 열 벡터  $a = (a_1, a_2, \dots, a_m)^T$ 에 대하여,  $a_i = \hat{a}$  또는 0, 즉  $i=1, \dots, m$ 일 때, 열 벡터  $\phi(a)$ 들의 집합  $\Phi(a)$ 은 다음과 같이 정의된다.

$$\Phi(a) = \{ \phi(a) \}, \quad (17)$$

여기서

$$\phi(a) = (\phi_1, \phi_2, \dots, \phi_m)^T, \quad (18)$$

$$\phi_i = 0 \text{ or } \hat{a}, \quad i = 1, \dots, m, \quad \sum_{i=1}^m \phi_i = \hat{a} \quad (19)$$

$\delta$ -합성 : 주어진  $m \times n$ 의 행렬  $R = [r_{ij}]$ 과  $1 \times n$ 행렬  $b = (b_1, b_2, \dots, b_n)$ 에 대한  $\delta$ -합성  $R \delta b$ 는 다음과 같은  $m \times n$ 의 행렬로 정의될 수 있다.

$$R \delta b = [s_{ij}] \quad (20)$$

$$s_{ij} = (\bigwedge_{k=1}^n (r_{jk} \alpha b_k) \beta (r_{ij} \alpha b_j)), \quad i=1, \dots, m, \quad j=1, \dots, n$$

위의 합성들과 집합에 대한 정의로부터 퍼지 관계 방정(14),  $b = a \circ R$ 의 해  $a$ 는 다음과 같이 구해진다.

$$\bigvee \phi(R^T \delta b) \leq a \leq \bigwedge (R^T \alpha b) \quad (21)$$

위의 (21)로 부터 각 고장 유형들의 고장 가능성을 구하였다. 이제, 각 고장 유형들의 고장 가능성으로부터 각 요소들의 고장 가능성을 구해야 한다[8]. 이를 위해 각 고장 유형들과 각 기본적 고장들간의 관계를 규정하는 전개 행렬(unfolding matrix)  $S$ 는 다음과 같이 정의된다.

$s_{ij} = 1$  : 고장  $a_j$ 가 기본적 고장  $x_i$ 를 포함하는 경우  
 0 : 고장  $a_j$ 가 기본적 고장  $x_i$ 를 포함하지 않는 경우 (22)

이제, 각 고장 유형  $a_j$ 에 대하여 집합  $I = \{i\}$ 를 규정할 수 있다. 집합  $I$ 는 기본적 고장  $x_i$ 가 고장 유형  $a_j$ 에 포함되는 경우의 집합이다.  $a_j$ 가  $x_i$  ( $i \in I$ )의 논리곱이므로  $a_j = \min_{i \in I} x_i$ 으로 나타낼 수 있다. 이는  $i \in I$ 인 경우  $s_{ij} = 1$ 이고 나머지 경우에는  $s_{ij} = 0$ 이므로,  $\alpha$ -합성과 전개 행렬  $S$ 에 의해  $a_j = \min_i (s_{ij} \alpha x_i)$ 로 나타낼 수 있다. 이를 행렬의 형태로 나타내면,

$$a = \wedge (S^T \alpha x) \quad (23)$$

위의 전개 방정식(unfolding equation), (23)의 해  $x$ 를 구함으로써 전개 행렬  $S$ 와 앞서 구한 고장 유형 벡터로부터 각 기본적 고장들의 가능성을 구할 수 있다.

전개 방정식의 해  $x$ 를 구하기 위하여 사용되는 합성들과 집합의 정의에 대하여 살펴보면 다음과 같다.

$\omega$ -합성 :  $m \times n$ 의 행렬  $R = [r_{ij}]$ 과  $n \times 1$ 행렬  $a$ 의  $\omega$ -합성  $R \omega a$ 는  $m \times n$ 행렬  $T = [t_{ij}]$

$$t_{ij} = [a \circ R]_i \gamma [R \alpha a]_{ij} = [\vee_k (r_{ik} \wedge a_k)] \gamma [r_{ij} \alpha a_j] \quad (24)$$

여기서,

$$a \gamma b = b : a \leq b \text{인 경우} \\ 1 : a > b \text{인 경우} \quad (25)$$

$\Psi$ -집합 : 주어진 열 벡터  $a = (a_1, a_2, \dots, a_m)^T$ 에 대하여,  $a_i = \hat{a}$  또는 1,  $i=1, \dots, m$ 일 때, 열 벡터  $\psi(a)$ 들의 집합  $\Psi(a)$ 는 다음과 같이 정의된다.

$$\Psi(a) = \{\psi(a)\} \quad (26)$$

여기서,

$$\psi(a) = (\psi_1, \psi_2, \dots, \psi_m)^T \quad (27)$$

$$\psi_i = 1 \text{ 또는 } a_i, i=1, \dots, m$$

$$\sum_{i=1}^m \psi_i = (m-1) + \hat{a} \quad (28)$$

위의 합성들과 집합에 대한 정의로부터 전개 방정식,  $a = \wedge (S^T \alpha x)$ 의 해  $x$ 는 다음과 같이 구해진다.

$$\wedge (S \omega a) \geq x \geq a \circ S \\ \forall \psi (S \omega a) \in \Psi(S \omega a) \quad (29)$$

위의 (29)로부터 기본적 고장 유형들의 고장 가능성을 구하였다. fault tree와 퍼지화된 증상을 이용한 퍼지 인과 방정식과 전개 방정식의 해는 fault tree의 기본적 고장들의 집합에 대한 상한과 하한값으로 표현된다. 일반적으로, 상한값과 하한값 사이의 범위를 갖는 해들의 수는 고장 진단과정에서 fault tree로부터의 정보가 얼마나 정확한가를 말해준다. 즉, 해의 개수가 작고 범위가 좁을수록 더욱 정확하고 유용한 해가 된다. 이러한 해의 유용성은 fault tree를 이루는 게이트들의 구조와 증상의 측정과정에서의 정확도와 특성에 좌우된다.


#### IV. 시뮬레이션 및 결과 고찰

##### 1. 시뮬레이션


##### 1.1 시뮬레이션 모델

유도전동기 고장 검출과 진단에 있어 회전자 권선 손상, 베어링 고장, 상 불평형을 고장 유형으로서 고려하였다. 유도전동기 고장 발생시 증상을 얻기 위해 유도전동기 모델을 EMTF(Electro Magnetic Transients Program)에 의하여 시뮬레이션 하였고 시뮬레이션 결과를 1Khz로 샘플링하였다. 시뮬레이션을 위한 운전 모델의 구성과 유도전동기는 그림

8, 표 1과 같다.



(a) 전기적 부분 모델



(b) 기계적 부분 모델

그림 8. 유도전동기 운전 모델.

Fig. 8. Models for induction motor operation.

표 1. 시뮬레이션을 위한 유도전동기 유형.

Table 1. Type of induction motor for simulation.

정 격	유도전동기 유형
최대 부하 전력	253.88 KVA
최대 부하 전압	420 V
최대 부하 슬립	0.015
최대 부하 역률	0.85
최대 부하 효율	90%
회 전 자 관 성	5 Kg · m <sup>2</sup>
기 계 적 뎀 평	0.5 Nt · m/rad/sec
동 작 슬 립	1 %

##### 1.2 고장 시뮬레이션 수행 고장 검출

그림 8과 표 1에 의한 본 논문에서 고려한 정상 운전 상태와 고장 유형들에 대한 유도전동기 유형1에서의 시뮬레이션 수행과 그 결과는 이후 고장 원인 진단을 위한 각 고장별 기준 입력 파형으로서 사용되며 다음과 같다.

##### 1) 회전자 권선 손상

회전자 권선 손상의 시뮬레이션은 정상 운전 상태의 전류 샘플링에 (2)의 주파수를 갖는 사인파를 샘플링 간격마다 첨가함으로써 수행되었다. 첨가된 사인파는 (30)과 같다.

$$e^{((t-t_0)/\tau)} - 1 \cdot e^{-k/c} \cdot \sin(2\pi * f_k(t-t_0)) \cdot U(t-t_0) \quad (30)$$

여기서,  $t$ 는 시뮬레이션상의 현재 시각,  $t_0$ 는 고장 발생 시각,  $\tau$ 는 발생한 고장의 진전(진폭의 증가) 속도를 조절하기 위한 것으로 실제로, 고장 여부의 결정에선 주파수 스펙트럼에서의 진폭이 중요할 뿐, 시간에 대한 진폭의 변화율은 관계없으므로 여기서는  $\tau = 100$ 의 값을 임의로 부여했다.  $k$ 는 고장 주파수의 고조파 성분들이 갖는 진폭의 상대적 크기를 규정하기 위한 것으로, 고조파의 차수가 높을수록 진폭이 작아지므로 고조파 차수의 지표를 음의 값으로 만들어 사용하였다. 상수  $c$ 는 회전자 권선 손상과 베어링 고장의 차이를 고려하기 위한 것으로, 회전자 권선 손상의 경우, 고장 주파수의 고조파 성분들에서의 감쇄가 베어링 고장에서보다 훨씬 작으므로 고조파 차수 증가로 인한 감쇄의 영향을 줄이기 위하여 사용하였다. 여기서 베어링 고장과의 구분을 고려하기 위하여 5의 값을 부여하였다.  $U(t)$ 는 계단함수이다. 시뮬레이션 결과는 그림 9와 같다. 회전자 권선

손상과 베어링 고장의 경우, 그 증상이 각 상에서 동일한 주파수대에서 발생하므로 한 상에서의 주파수 분석만으로도 충분하다.

2) 베어링 고장

베어링 고장의 시뮬레이션은 정상 운전 상태의 전류 샘플링에 (3)-(6)의 주파수를 갖는 사인파를 샘플링 간격마다 첨가함으로써 수행되었다. 첨가된 사인파는 (30)과 같다. 사인파 조작용을 위한 파라미터는 c의 값이 1로서 작은 것을 빼고는 회전자 권선 손상의 경우와 동일하다. 시뮬레이션 결과는 그림 10과 같다.

3) 상 불평형

상 불평형(그림 8)은 SWITCHR, SWITCHS, 또는 SWITCHT를 시각  $t=t_0$ 에 닫아 상 A, B 또는 C의 전로 저항값을 제거하여 불균등하게 만듦으로써 구현된다. 이 때, 닫히는 스위치의 개수는 단일 상의 불평형인 경우 1개, 두 상의 불평형인 경우 2개가 된다. 시뮬레이션 결과는 그림 11과 같다.

4) 결상

결상(그림 8)은 SWITCHA, SWITCHB, 또는 SWITCHC를 시각  $t=t_0$ 에 열어 상 A, B 또는 C에 공급되는 전원을 차단함으로써 구현된다. 이 때, 닫히는 스위치의 개수는 상 불평형의 경우와 같다. 시뮬레이션 결과는 그림 12와 같다.

위의 설정에 의한 시뮬레이션결과로부터 시각 t에서의 입력전류 패턴은 다음과 같다.

$$pattern_t = \frac{S}{|S|} \quad (31)$$

여기서,

$S = [s_A \ s_B \ s_C]$ ,  $s_x$  : x상 전류입력의 샘플링 FFT결과 벡터

2. 고장 검출

고장 검출을 위한 기준으로서 필요한 Dignet의 신호대잡음비와 추가로 발생하는 클러스터의 최소 수를 결정함에 있어, 신호대잡음비를 너무 작게 하는 경우, 클러스터 생성의 민감도가 높아져, 정상상태에서 많은 클러스터의 생성으로 인한 메모리 부족과 외란을 고장으로 오판하는 경우가 있을 수 있다. 반대의 경우, 클러스터가 적게 생성되어 메모리의 부족은 없겠으나 고장을 외란으로 오판하거나 고장 검출이 늦어지는 경우가 있을 수 있다. 따라서, 신호대잡음비와 고장시 추가로 발생하는 클러스터의 수를 설정함에 있어, 정상 상태 운전중 반복되는 부하 주기동안 과도한 클러스터가 발생되지 않도록 신호대 잡음비를 설정해줄 필요가 있으며 클러스터 수의 설정은 설정된 신호대 잡음비에 의해 생성된 정상 상태 클러스터들이 많은 경우 크게, 적은 경우 작게 설정한다. 이에 대한 설정은 부하의 특성에 크게 좌우되므로 정량화된 규칙을 찾기 어려웠으며, 정상 운전 초기에 운전자의 모니터링에 의한 결정에 따라야 할 것으로 보인다. 본 논문에서는 1.692db의 신호대잡음비와 정상 상태에서부터 5개의 클러스터가 추가로 생성되는 경우를 고장 발생의 검출 기준으로 하였고, 이에 의한 고장 검출과 이 때 나타난 고장 증상들을 살펴보면 다음과 같다.

1) 회전자 권선 손상

그림 9(a)는 회전자 권선 손상 검출 시점에서의 입력전류의 스펙트럼으로서 전원 주파수 주변에서 증상이 크게 나타나고 그 밖의 주파수 영역에선 빠르게 감쇄하는 것을 알 수 있다. 고장이 검출될 때까지의 클러스터 개수의 변화는 그림 9(b)와 같다.

2) 베어링 고장

그림 10(a)는 베어링 고장 검출 시점에서의 입력전류의 스펙트럼으로서 회전자 권선 손상의 경우와는 달리 넓은 주파수대에서 그 증상이 나타나는 것을 알 수 있다. 고장이 검출

될 때까지의 클러스터 개수의 변화는 그림 10(b)와 같다.




그림 9. 회전자 권선 손상시 스펙트럼과 클러스터 수의 변화.

Fig. 9. Spectrum for broken rotor bar and change in number of clusters.




그림 10. 베어링 고장시 스펙트럼과 클러스터 수의 변화.

Fig. 10. Spectrum for bearing fault and change in number of clusters.

3) 상 불평형

그림 11(a)는 상A의 저항 값이 감소하여 불평형이 발생한 경우, 고장 발생 후 입력전류 파형의 시간에 따른 변화이다. SWITCHR에 의해 상A의 저항 값이 감소하여 그림 11(a)의 A상 입력전류의 진폭이 고장 발생 즉시 크게 증가하는 것을 볼 수 있다. 그림 11(b)는 고장 검출시 입력전류의 스펙트럼으로서, 상A의 경우 전원 주파수 부근에서 진폭이 높게 나타나고 있다. 이러한 증상에 의한 클러스터 개수의 변화는 그림 11(c)와 같다. 앞서의 회전자 권선 손상과 베어링 고장의 경우와 달리 고장의 증상이 급격히 발생하므로, 클러스터가 단시간 내에 다수 발생하므로 고장 검출에 소요되는 시간 또한 짧다.

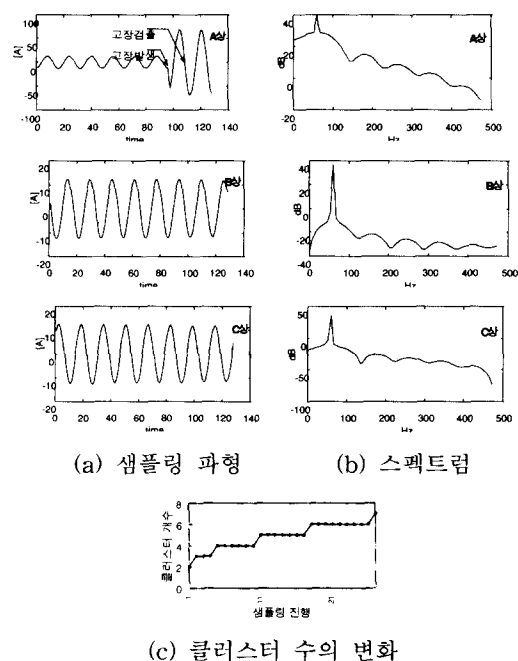


그림 11. A상 불평형시 파형과 클러스터 수의 변화.

Fig. 11. Waves and change in number of clusters for phase A unbalance.

4) 결상

그림 12(a)는 상A에 결상이 발생한 경우, 입력전류의 변화로서, 상A의 전류가 고장 발생 즉시 급격히 감소함을 알 수 있다. 상A의 입력 전류가 완전히 소멸하지 않는 것은, 유도 전류의 고저항 접지로의 유입에 의한다. 그림 12(b)는 고장 검출시의 입력전류 스펙트럼으로서, 상A의 전원 주파수 성분이 나머지 상에 대하여 상대적으로 작게 나타나는 것을 알 수 있다. 이러한 증상에 의한 클러스터 개수의 변화는 그림 12(c)와 같으며, 상 불평의 경우와 유사하게 클러스터 개수의 증가가 빠른 것을 알 수 있다.

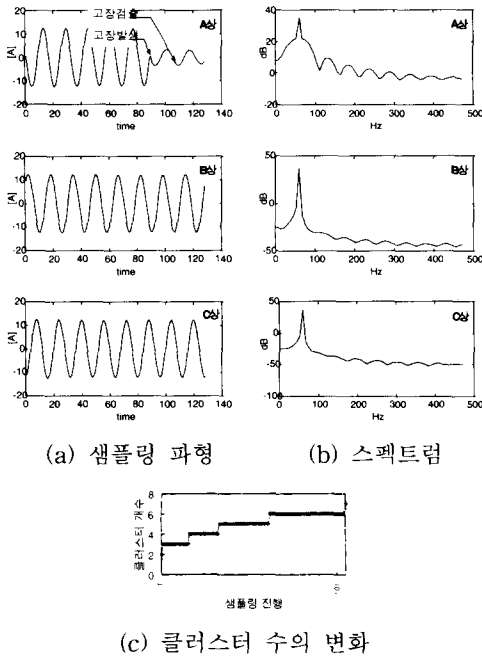


그림 12. A상 결상시 파형과 클러스터 수의 변화.  
Fig. 12. Waves and change in number of clusters for phase A loss.

3. fault tree구성과 고장 증상의 퍼지화

3.1 fault tree 구성

앞서 2장에서 살펴보았던 고장 유형들과 전동기 운전 상태의 관계를 나타내는 fault tree를 구성은 그림 13과 같다.




그림 13. 유도전동기 고장 진단을 위한 fault tree.  
Fig. 13. Fault tree for diagnosing induction motor faults.

그림 13에서

- g1 : 시스템으로서의 전동기 고장 가능성
- g2 : 공극 이상 발생 가능성
- g3 : 상 A의 고장 가능성
- g4 : 상 B의 고장 가능성
- g5 : 상 C의 고장 가능성
- x1 : 회전자 권선 손상 가능성
- x2 : 베어링 고장 가능성
- x3 : 상 A 불평형 가능성
- x4 : 상 A 결상 가능성
- x5 : 상 B 불평형 가능성
- x6 : 상 B 결상 가능성
- x7 : 상 C 불평형 가능성
- x8 : 상 C 결상 가능성

이며, 각 단계에서의 정량화가 가능한 증상들과 그들의 정량화는 다음과 같다.

3.2 고장 증상의 정량화

입력전류 스펙트럼으로부터 검출하고자 하는 고장여부를 알아내기 위해 각 고장이 발생했을 경우 이를 다른 고장들과 구별하기 위한 기준이 마련되어야 한다. 즉, 각 고장간의 구별을 위해 각 증상들을 정량화할 필요가 있는데 이는 각 고장이 발생했을 경우 나타나는 스펙트럼의 특징으로부터 기인한다. 특징에 대한 분석은 전동기 동작 원리와 시뮬레이션에 의한다.

우선, 그림 9~12의 결과로부터 각 고장 유형 발생시 나타나는 증상들에 대한 구별과 정량화는 다음과 같다.

1) 공극 이상 발생(g2)과 각 상 고장 발생(g3, g4, g5)의 구별

임의 상에 고장이 발생하는 경우, 삼상간의 평형이 깨져 입력 전류의 크기가 가장 큰 상과 입력 전류의 크기가 가장 작은 상간의 전원 주파수대에서의 성분 크기가 커지게 된다. 그러나, 공극 이상 발생의 경우, 전원 주파수이외의 주파수대에서 고장 증상이 각 상에 동일하게 나타나므로 전원 주파수 성분이 거의 평형을 이룬다. 즉,

$$g2 = (p_{max} - p_{min})$$

$$p_{max} = \max(p_{Af=60Hz}, p_{Bf=60Hz}, p_{Cf=60Hz})$$

$$p_{min} = \min(p_{Af=60Hz}, p_{Bf=60Hz}, p_{Cf=60Hz})$$

의 값이 공극 이상 발생의 경우 매우 작고, 상 고장이 발생한 경우 이 값이 매우 크다.

여기서,  $p_{if=60Hz}$  : i상 전류 스펙트럼에서의 60Hz성분

2) 각 상 고장 발생시 고장 발생 상의 구별 (g3, g4, g5 구별) 상 고장이 발생한 경우, 위의 (1)의 결과는 g3, g4, g5 모두에 해당되므로 위 (1)의 결과로는 구별이 어렵다. 따라서, 각 상에 상 불평형 또는 결상이 발생하였을 경우, 각 상에서 나타나는 증상을 살펴보면, 고장 전에 비하여 고장 후, 상 전류 값이 크게 변화하는 것을 관찰할 수 있다. 상 전류의 변화는 상 불평형의 경우 증가와 감소의 두 경우가 모두 있을 수 있으므로 변화의 절대적 크기만을 생각하도록 한다. 즉, 상 전류의 크기 변화가 클수록 고장의 가능성이 크므로 (33)과 같이 정량화할 수 있다.

$$\frac{|p_{if=60Hz}(t) - p_{if=60Hz}(t-t_0)|}{\sum_{i=A,B,C} |p_{if=60Hz}(t) - p_{if=60Hz}(t-t_0)|}$$

여기서  $p_{if=60Hz}(t-t_0)$  : 고장 검출  $t_0$  전 i상 전류 스펙트럼에서의 60Hz성분

3) 공극 이상 발생시 회전자 권선 손상과 베어링 고장의 구별(x1, x2구별)

일단 공극 이상 발생의 가능성이 높다면 그것은 곧, 회전자 권선 손상 또는 베어링 고장이 발생한 것으로 볼 수 있다. 고장 시뮬레이션결과 그림 9-10에 의하면 전원 주파수 이외의 주파수대에서 발생하는 성분들의 합을 살펴보면 베어링 고장의 경우가 더 작게 나오는 것을 알 수 있다. 이로부터 베어링 고장시 증상을 정량화하면 다음과 같다.

$$\frac{\sum_{f=0}^{nyquist\_freq} p_f(\text{전원주파수성분 제외})}{\sum_{f=0}^{nyquist\_freq} p_f}$$

$$p_f = p_f \text{ if } p_f \geq TH, 0 \text{ if } p_f < TH$$

여기서  $p_f$  = 주파수 f에서의 파워

TH = 유효한 스펙트럼 성분을 거르기 위한 문턱 값 (전원 주파수를 제외한 스펙트럼 성분들의 평균)



4) 상 고장 발생시 상 불평형과 결상의 구별 (x3,x4 : x5,x6 : x7,x8의 구별)

상 고장이 발생한 경우 상 불평형 또는 결상이 발생한 것으로 볼 수 있다. 상 불평형의 경우, 그 증상이 상 전류의 증가와 감소 두 경우 모두 일어날 수 있으므로 전류량의 변화 만으로 구별이 어렵다. 그러나, 결상의 경우, 전원 공급의 차단이 일어나므로 전류량의 크기가 매우 작을 수밖에 없다.

$$\sum_{i=A,B,C} P_{if=60Hz} \quad (35)$$

3.3 고장 증상의 퍼지화

위에서 전동기와 환경의 동특성을 고려하기 위하여 정량화된 증상들을 퍼지화한다. 이들 정량화된 증상들의 퍼지화를 위한 규칙과 멤버십 함수는 정량화된 증상의 크기와 고장 가능성의 관계에 따라 정해지며, 함수의 유형은 그림 14와 같으며 멤버십 함수의 구체적 결정을 위한 파라미터의 값은 표 2와 같다.




그림 14. 멤버십 함수.

Fig. 14. Membership function.

정량화된 고장 증상의 퍼지화를 위한 멤버십 함수의 형태를 결정하는 위의 파라미터 값들은 시뮬레이션 결과들로부터 각 고장 유형들의 정량화된 값들이 갖는 분포로부터 결정하였다.

표 2. 증상별 멤버십 함수 파라미터.

Table 2. Parameters of membership function for each symptom.

	a	b	c	d
g2	0.0	0.00001	0.003	0.001
g3	0.0	0.5	0.99	1.0
g4	0.0	0.5	0.99	1.0
g5	0.0	0.5	0.99	1.0
x2	0.3	0.33	0.334	0.335
x4	0.0	0.001	0.3	0.4
x6	0.0	0.001	0.3	0.4
x8	0.0	0.001	0.3	0.4

4. 고장 진단

정량화된 고장 증상의 퍼지화에 의해 구해진 각 고장의 가능성으로부터 이제 어떤 종류의 고장이 발생하였는지를 결정할 수 있다. 우선 3.3.3에서 정의되었던 기본적인 고장들의 발생 가능성의 집합 X, 발생할 수 있는 모든 고장 유형별 발생 가능성 A, 증상을 정량화할 수 있는 고장들의 발생 가능성의 집합 B를 정의하면 다음과 같다.

$$X = \{x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8\} \quad (36)$$

$$A = \{x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_3 \wedge x_5, x_4 \wedge x_6\} \quad (37)$$

$$B = \{g_2, g_3, g_4, g_5, x_2, x_4, x_6, x_8\} \quad (38)$$

그림 9의 fault tree와 집합 X, A, B에 근거하여 (12)에 따라 인과 행렬 R을 구하면 다음과 같다.

$$R(1:5, :) = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 1 \end{pmatrix} \quad (39)$$

$$R(6:9, :) = \begin{pmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \end{pmatrix}$$

(22)에 따라 전개 행렬 S는 다음과 같다.

$$S = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{pmatrix} \quad (40)$$

(21),(29)에 의하여 각 고장별 고장 진단 결과는 표 3, 4, 5와 같다. 집합 X에서 발생한 고장 유형에 해당하는 기본적인 고장의 원소는 음영 처리하였다.

표 3, 4, 5에서 보는 바와 같이 단일 고장이 발생한 경우, 그에 해당하는 기본적인 고장 원소의 고장 가능성이 다른 기본적인 고장 원소들의 고장 가능성에 비하여 큰 값을 가지는 것을 볼 수 있다.

표 3. 각 고장별 정량화할 수 있는 증상들의 퍼지화된 값.

Table 3. Fuzzified value which can be normalized for each fault.

	행렬 B								
	g1	g2	g3	g4	g5	x2	x4	x6	x8
회전자 권선손상	0.9 9	0.9 6	0.6 2	0.7 0	0.6 8	0.0 0	0.6 7	0.6 7	0.6 6
베어링 고장	0.9 9	0.7 2	0.6 6	0.6 4	0.6 9	0.6 7	0.6 7	0.6 6	0.6 7
상 A 불평형	0.9 9	0.0 0	0.9 8	0.0 1	0.0 1	0.0 0	0.0 0	0.9 8	0.9 8
상 A 결상	0.9 9	0.0 0	0.9 8	0.0 2	0.0 3	0.0 0	0.9 8	0.0 0	0.0 0
상 A, B 불평형	0.9 9	0.0 0	0.9 8	0.9 4	0.0 1	0.0 0	0.0 0	0.0 0	0.9 8
상 A, B 결상	0.9 9	0.0 0	0.9 5	0.9 9	0.0 5	0.0 0	0.9 8	0.9 8	0.0 0

표 4. 인과방정식 B = A · R의 해 A.

Table 4. The solution A of causality equation B = A · R.

	행렬 A									
	x1	x2	x3	x4	x5	x6	x7	x8	x3 ∧ x5	x4 ∧ x6
회전자 권선손상	0.9 7	0.0 0	0.6 3	0.6 3	0.7 3	0.6 7	0.6 8	0.6 6	0.6 3	0.3 7
베어링 고장	0.7 3	0.6 7	0.6 7	0.6 7	0.6 4	0.6 4	0.6 9	0.6 7	0.6 4	0.6 4
상 A 불평형	0.0 0	0.0 0	0.9 8	0.0 0	0.0 1	0.0 1	0.0 1	0.0 1	0.0 1	0.0 0
상 A 결상	0.0 0	0.0 0	0.9 8	0.0 0	0.0 2	0.0 3	0.0 0	0.0 0	0.0 2	0.0 0
상 A, B 불평형	0.0 0	0.0 0	0.9 8	0.9 8	0.9 9	0.0 4	0.0 1	0.0 1	0.9 4	0.0 0
상 A, B 결상	0.0 0	0.0 0	0.9 6	0.9 6	0.9 9	0.9 8	0.0 5	0.0 0	0.9 6	0.0 5

두 가지의 고장이 복합적으로 발생한 경우 해당되는 두 고장 원소들의 고장 가능성이 비슷하게 높게 나오는 것을

알 수 있다. 즉, 고장이 발생한 경우, 해당 종류의 고장 항목에서 고장 가능성이 상대적으로 높은 값으로 나타난다는 것을 알 수 있다.

표 5. 전개방정식  $A = \wedge(S^T a x)$ 의 해 X.  
Table 5. The solution X of unfold equation  $A = \wedge(S^T a x)$ .

	X							
	x1	x2	x3	x4	x5	x6	x7	x8
회전자 권선 손상	0.97	0.0	0.63	0.67	0.70	0.67	0.68	0.66
베어링 고장	0.67	0.73	0.67	0.67	0.64	0.64	0.69	0.67
상 A 불평형	0.00	0.00	0.98	0.00	0.01	0.01	0.01	0.01
상 A 결상	0.00	0.00	0.00	0.98	0.02	0.00	0.03	0.00
상 A, B 불평형	0.00	0.00	0.98	0.00	0.94	0.00	0.01	0.01
상 A, B 결상	0.00	0.00	0.14	0.96	0.56	0.98	0.05	0.05

V. 결론

본 논문에서는 다양한 부하 환경과 용량을 가지는 유도전동기의 운전 도중 발생하는 고장을 적시에 발견하고, 고장의 원인을 진단하기 위한 알고리즘의 개발을 목적으로 하였다. 이를 위하여 본 연구에서는 유도전동기 상태 모니터링을 위한 수단으로 입력 전류의 주파수 스펙트럼을 사용하였다. 입력 전류 스펙트럼의 클러스터링을 통해 고장 발생 시 새로운 형태로 나타나는 스펙트럼 패턴을 감지함으로써 고장을 검출하였다. 검출된 고장의 원인을 진단하기 위해 fault tree를 구성하여 유도전동기 고장과 각 고장 유형들간의 관계를 퍼지 관계식(fuzzy relation equation)으로 표현한 후, 그 해를 구함으로써 고장 원인을 진단하였다.

고장 검출을 위한 클러스터링 방법으로 비교사학습 클러스터링 기법인 Dignet을 도입하였다. 고장 진단 과정에서 퍼지 관계 방정식을 풀기 위한 조건인, 각 고장 유형의 발생 가능성을 얻기 위하여 발생한 고장 스펙트럼 패턴과 각 고장 유형간의 관계를 정량화한 후 이의 퍼지화를 통해 각 고장 유형들의 발생 가능성을 구함으로써 전동기와 운전 환경의 동적 특성을 고려하였다.

연구 수행을 통해 얻은 주요 결과는 다음과 같다.

- (1) 유도전동기 고장 검출 및 진단을 위하여, 입력 전류의 주파수 분석만을 이용함으로써 전동기를 해체하거나 별도의 하드웨어적 장치 없이 기존 디지털 보호 계전기의 소프트웨어 첨가만을 통해, 유도전동기 고장 발생을 운전 도중에도 검출하고 진단할 수 있는 온라인 고장 검출 방법을 제시하였다.
- (2) 고장 검출을 위해 비교사학습에 의한 클러스터링 기법을 적용함으로써, 유도전동기 부하 특성과 용량, 그리고 구조 등에 영향을 받지 않는 고장 검출 기법을 고안할 수 있었으며, 고장 검출 과정에서의 전문가 의존도를 낮추었다.
- (3) 퍼지 fault tree를 이용하여 발생한 고장에 대하여 고장 종류를 진단함으로써, 고장 진단을 위한 체계적 방법을 제시하였으며, 전체 계통에 대하여 퍼지 fault tree에 의한 고장 진단을 수행하는 경우를 생각할 때, 계통내 각 부분들에 대한 고장 진단을 객체화함으로써 구성이 요소의 첨가, 교체, 감소 등에 의해 자주 변동되는 계통의 고장 진단이 용이해지며, 그 중 전동기 고장 진단 단계를 수행하는 하나의 모듈화된 객체를 고안한 것으로 볼 수 있다.

위의 결과에서 제안된 고장 검출과 진단 기법을 사용함에 있어, 유도전동기 상태 모니터링을 위한 수단으로 전동

기 입력 전류만을 사용하였으나, 가속 센서, 축 코일 등의 센싱 수단을 보강함으로써, 더욱 다양한 종류의 고장을 검출하고 더욱 정밀한 진단이 가능할 것이다.

참고문헌

- [1] J. Penman, H. G. Sedding and W. T. Fink, "Detection and location interturn short circuits in the stator winding of operation motors," *IEEE Trans. on Energy Conversion*, vol. 9, no. 4, pp. 652 - 658, Dec., 1994.
- [2] M.-Y. Chow, P. M. Mangum and S. O. Yee, "A neural network approach to real-time condition monitoring of induction motors," *IEEE Trans. on Industrial Electronics*, vol. 38, no. 6, pp. 448 - 453, Dec., 1991.
- [3] G. B. Kliman, J. Stein and R. D. Endicott, "Noninvasive detection of broken rotor bars in operating induction motors," *IEEE Trans. on Energy Conversion*, vol. 3, no. 4, pp. 873 - 879, Dec., 1988.
- [4] ASEA RELAYS, Type RAMDE : Motor Protection, UG03-4511E User's Guide, pp. 17 - 18, Sep., 1987.
- [5] R. R. Schoen, T. G. Gabetler, F. Kamran and R. G. Bartheld, "Motor bearing damage detection using stator current monitoring," *IEEE Trans. on Industry Applications*, vol. 31, no. 6, pp. 1274 - 1279, Nov./Dec., 1995.
- [6] R. R. Schoen, B. K. Lin, T. G. Habetler, J. H. Schlag and S. Farag, "An unsupervised, on-line system for induction motor fault detection using stator current monitoring," *IEEE Trans. on Industry Applications*, vol. 31, no. 6, pp. 1280 - 1286, Nov./Dec., 1995.
- [7] S. C. A. Thomopoulos, D. K. Bougoulas, and C.-D. Wann, "Dignet : an unsupervised-learning clustering algorithm for clustering and data fusion," *IEEE Trans. on Aerospace and Electronic Systems*, vol. 31, no. 1, pp. 21 - 38, Jan., 1995.
- [8] P. Gmytrasiewicz, J. A. Hassberger and J. C. Lee, "Fault tree based diagnostics using fuzzy logic," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 12, no. 11, pp. 1115 - 1119, Nov., 1990.
- [9] C. P. Pappis and M. Sugeno, "Fuzzy relational equations and the inverse problem," *Fuzzy Sets and Systems*, vol. 15, pp. 79 - 90, 1985.
- [10] Laurene Fausett, *Fundamentals of Neural Networks Architectures, Algorithms and Applications*, Prentice-Hall, Inc 1994.
- [11] W. S. Lee, D. L. Grosh and C. H. Lie, "Fault tree analysis, methods and applications - A review," *IEEE Trans. on Reliability*, vol. R-34, no. 3, pp. 194 - 203, Aug., 1985.
- [12] H. J. Zimmermann, *Fuzzy Set Theory - and Its Applications*, Kluwer-Nijhoff Publishing, 1985.



**이 성 환**

1990년 연세대 전기과 졸업. 동 대학원 석사(1992). 동 대학원 박사과정 수료 (1995). 1995년~현재 현대중공업 마북리연구소 연구원. 관심분야 시스템제어, 지능형 제어.



**우 천 희**

1985년 연세대 전기과 졸업. 동대학원 석사(1993). 1995년~현재 연세대학교 전기공학과 박사과정. 1985년~1995년 현대중공업 마북리연구소 선임연구원. 1995년~현재명지전문대 전기과 조교수. 관심분야 시스템제어, 디지털 보호 계전 기, 마이크로프로세서 응용등.




**신 현 익**

1995년 연세대 전기과 졸업. 동대학원 석사(1997). 1997년~현재 삼성전자 System LSI 본부 주임 연구원. 관심분야 BLDC, VCM motor drive IC 설계.

**우 광 방**

제어·자동화·시스템공학회 논문지 제 3권 제 2호 참조.



**강 신 준**

1992년 연세대 전기과 졸업. 동대학원 석사(1994). 1994~현재 연세대학교 전기 공학과 박사과정. 관심분야 지능형 제어.