

클러스터링 기법을 이용한 3상 유도전동기 구동시스템의 고장진단

(Fault Diagnosis of 3 Phase Induction Motor Drive Systems Using Clustering)

박장환* · 김승석 · 이대종 · 전명근

(Jang-Hwan Park · Sung-Suk Kim · Dae-Jong Lee · Myung-Geun Chun)

요약

산업 응용분야에서 유도전동기 구동시스템의 예상치 않은 고장은 전체 계통의 정지, 막대한 손실 등을 가져올 수 있다. 이러한 문제점을 해결하는 방법 중에 하나로서 본 논문은 유도전동기 구동을 위한 3상 전압형 PWM 인버터에 개방-스위치 손상의 고장진단에 대하여 연구한다. 고장진단 방법으로는, 먼저 고장의 특징추출을 위하여 3상 전류를 d-q 전류로 변환한 후 평균 전류벡터를 구한다. 다음으로 여러 종류의 고장 패턴을 진단하기 위하여 한 인공지능 알고리즘을 제안한다. 제안된 기법은 일반적인 뉴로-퍼지 시스템(adaptive neuro-fuzzy algorithm)의 전제부에 클러스터링을 도입한 기법으로 적은 계산 양과 좋은 성능을 갖는다. 최종적으로, 여러 불확실한 요소를 가진 고장계통에 대하여 제안된 알고리즘의 유용성을 모의실험에 의해 검증하였다.

Abstract

In many industrial applications, an unexpected fault of induction motor drive systems can cause serious troubles such as downtime of the overall system, heavy loss, and etc. As one of methods to solve such problems, this paper investigates the fault diagnosis for open-switch damages in a voltage-fed PWM inverter for induction motor drive. For the feature extraction of a fault, we transform the current signals to the d-q axis and calculate mean current vectors. And then, for diagnosis of different fault patterns, we propose a clustering based diagnosis algorithm. The proposed diagnostic technique is a modified ANFIS(Adaptive Neuro-Fuzzy Inference System) which uses a clustering method on the premise of general ANFIS's. Therefore, it has a small calculation and good performance. Finally, we implement the method for the diagnosis module of the inverter with MATLAB and show its usefulness.

Key Words : fault diagnosis, induction motor drive system, inverter, ANFIS

1. 서론

* 주저자 : 충주대학교 정보제어공학과

Tel : 043-841-5463, Fax : 043-841-5320

E-mail : parkjh@mail.chungju.ac.kr

접수일자 : 2004년 6월 8일

1차심사 : 2004년 6월 14일, 2차심사 : 2004년 8월 24일

심사완료 : 2004년 10월 8일

인버터는 많은 산업분야에서 광범위하게 사용하고 있다. 특히, 유도전동기의 속도제어를 위한 효과적인 방법으로 고정자의 전압과 주파수를 조정하는

것이 필요하며, 이것을 위해 일반적으로 인버터와 같은 전력전자 회로로부터 에너지를 공급을 받는다. 이러한 인버터들은 두 가지 형태인 전압형 인버터와 전류형 인버터가 있으며, 산업분야에 응용되는 소형/중형 마력 범위에서는 전압형 인버터를 일반적으로 사용한다.

전기기기들의 고장 검출과 진단은 고장-허용 측정 및 제어 계통들의 고 신뢰도 관점에서 매우 흥미 있는 주제이다. 그러한 고장검출과 진단을 하기 위한 전통적인 기법은 고장 메커니즘의 해석이나 전문가의 지식에 크게 의존한다. 반면 인공지능 기법은 이러한 구속 없이도 목적을 달성할 수 있으므로, 근래에는 고장 진단을 위한 방법으로 폭넓게 응용되고 있다.

3상 유도전동기 구동을 위한 전압형 인버터의 고장의 발생은 예정치 않은 보수계획에 의해 전체 계통을 갑자기 정지시키는 일을 초래한다. 이러한 재해들은 높은 신뢰도를 중시하는 속도조절 구동을 적용하는 계통에서 심각한 손실을 줄 수 있다. 이러한 계통들을 위해서, 고장을 검출하는 것과 고장의 위치를 인식하는 것은 매우 유용하며, 그것은 신뢰도의 증가 측면에서 고장진단 기법들의 개발의 필연성을 시사한다. 그런 까닭에, 여러 논문들에서 인버터의 고장을 검출을 하고 진단하기 위한 방법들을 논의하였다. 먼저 고장 및 진단을 위한 그 방법들은 먼저 인버터 고장 검출 및 진단을 위한 신호의 관점에서 보면, 상전압의 측정 값[1], 상전류의 d-q축 변환 값[2], 상전류의 스펙트럼 값[3] 등을 이용하고 있다. 또한, 최근에 인버터의 고장 검출 및 진단 기법의 관점에서, 전문가 시스템[4] 및 인공 신경망 기법들[5]에 대한 연구 결과가 있다.

본 논문은 클러스터링에 기반을 둔 뉴로-퍼지시스템을 이용한 3상 유도전동기 구동용 인버터의 고장검출 및 진단 방법을 제안한다. 일반적으로, 뉴로-퍼지시스템의 입력 공간에 그리드 분할을 적용하면 지수적으로 퍼지 규칙들의 수가 증가한다[6][7]. 그런 까닭에, 이 논문은 학습시간과 퍼지 규칙들의 수를 효과적으로 감소시키기 위해 클러스터링 기법에 기반을 두고 있다. 여기서, 클러스터링의 입력 패턴으로는 d-q 상 전류의 한 주기 평균값들을 사용하

였다.

본문의 내용으로, 2장에서는 고장 진단 및 검출을 위해 제안된 클러스터링 기법에 대하여 기술한다. 3장과 4장에서는 인버터의 고장에 대해서 간략한 해석을 보여주며, 여러 불확실한 요소를 고려한 신호에 적용한 제안된 알고리즘의 유용성을 시뮬레이션에 의해 보여준다. 5장은 결론과 향후 과제를 기술하였다.

2. 클러스터링 기반 진단 알고리즘

클러스터링에 기반을 두는 제안된 진단 기법은 그림 1에서 보인 바와 같이 데이터 획득, d-q 변환, 특징 추출, 진단 부분으로 구성된다. 데이터는 유도전동기 입력 단의 3상 전류 i_u , i_v 와 i_w 을 식 (1)에 의해 d-q 변환을 한다.

$$\begin{bmatrix} i_d \\ i_q \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & -1/2 & -1/2 \\ 0 & \sqrt{3}/2 & -\sqrt{3}/2 \end{bmatrix} \begin{bmatrix} i_u \\ i_v \\ i_w \end{bmatrix} \quad (1)$$

특징 추출은 평균 전류벡터 I_{av} 을 가지고 하며, 다음과 같이 계산한다.

$$I_{av} = \frac{1}{N} \left[\sum_{n=1}^N i_d(n) + j \sum_{n=1}^N i_q(n) \right] = |I_{av}| \angle \theta_{av} \quad (2)$$

여기서, N 은 전원의 한 주기 동안 표본들의 수이며, $i_d(n)$ 과 $i_q(n)$ 은 n 번째 d-q 상전류이다.

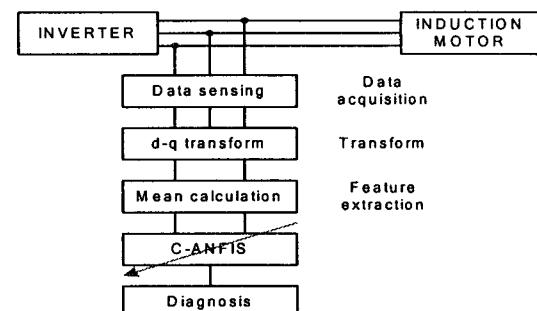


그림 1. 고장 진단의 구성도

Fig. 1. The flowchart for fault diagnosis

클러스터링 기법을 이용한 3상 유도전동기 구동시스템의 고장진단

상기한 식 (2)에 의해 취득된 평균벡터를 이용하여 인버터 계통의 고장진단을 위해 본 논문에서는 클러스터링 기반 뉴로-퍼지시스템을 적용한다. 일반적으로 뉴로-퍼지시스템(ANFIS)는 언어적 입력과 다항식을 출력으로 가지는 TSK(Takagi-Sugeno-Kang) 퍼지 모델이며, 전방향 학습은 최소자승법과 역방향 학습은 오류 역전파 알고리즘을 이용하여 시스템을 학습한다. 이러한 TSK 퍼지 모델의 기본구조는 다음과 같다[8][9].

$$R^1: \text{IF } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ THEN } f_1 = p_1x + q_1y + r_1 \quad (3)$$

$$R^2: \text{IF } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ THEN } f_2 = p_2x + q_2y + r_2$$

여기서, x, y 는 입력, A_i, B_i 는 소속함수이고 p_i, q_i, r_i 는 결론부 파라미터들이다. 유도전동기 고장진단 문제에서는 x, y 는 각각 i_d 와 i_q 의 한 주기 평균값이고, $f_i, i=1, 2$ 는 최종 출력 값, 즉, 고장진단의 결과이다.

(3)을 각각의 층으로 나누어 보면 다음과 같다.

layer 1 : 이 층의 모든 노드는 다음과 같은 소속값을 가진 출력을 가진다.

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), \quad \text{for } 1, 2 \\ O_{2,i} &= \mu_{B_i}(y), \quad \text{for } 3, 4 \end{aligned}$$

여기서,

$$\mu_{A_i}(x) = \exp\left\{-\frac{1}{2}(x - c_i)^T \Sigma_i^{-1} (x - c_i)\right\}$$

layer 2 : 1층에서 구한 소속 값을 각 규칙의 곱으로 가중치를 나타낸다.

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i=1, 2$$

layer 3 : 모든 노드는 다음과 같이 정규화 된 가중치 값으로 출력하게 된다.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1, 2$$

layer 4 : 정규화된 가중치 값과 결론부의 곱으로

출력을 나타낸다.

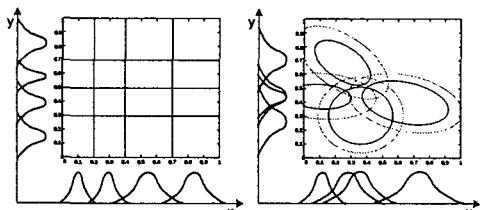
$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$$

layer 5 : 가중 평균법(weighted average method)에 의한 최종 출력을 구한다.

$$O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i \bar{w}_i f_i}{\sum_i \bar{w}_i}$$

일반적인 뉴로-퍼지시스템에서 전제부의 소속함수와 결론부의 소속함수는 각각의 퍼지규칙으로 연결되어 있으며, 이 경우 입력과 소속함수의 수에 대하여 일대일 대응을 하게 될 경우 입력의 차원이나 소속함수의 수가 증가할 경우 지수함수 형태로 퍼지규칙이 증가하는 문제점을 가지고 있다(그림 2-(a)). 이 논문에서는 그러한 문제점을 클러스터링 기법을 이용하여 해결한다. 데이터 클러스터링은 뉴로-퍼지모델의 초기 구조 및 파라미터를 인식한다. 즉, 클러스터링 파라미터는 뉴로-퍼지 시스템의 전제부 소속함수의 수 및 파라미터, 규칙을 결정한다. 결과적으로, 클러스터링 기법에 의한 퍼지 규칙은 입력의 차원과는 무관하고 단지 소속함수의 수와 같아지게 되므로, 규칙의 증가에 의하여 발생하는 학습 시간 증가와 모델의 크기 증가를 동시에 줄여 줄 수 있다(그림 2-(b)). 그림 2는 횡축은 식 (3)에서 설명한 x , 종축은 y 이고, 상기한 클러스터의 강소를 도시적으로 보여준다.

그림 3에서는 클러스터링 기반 뉴로-퍼지시스템의 구조를 나타냈다. 여기서, 입·출력 파라미터들은 그림 2와 같이 x, y 는 d-q 전류의 한 주기 평균값이고, f_i 는 고장진단의 결과 값이다.



(a) 그리드 분할

(b) 스캐터 분할

그림 2. 그리드 분할과 스캐터 분할에 의한 클러스터링
Fig. 2. Grid and scatter partition for clustering

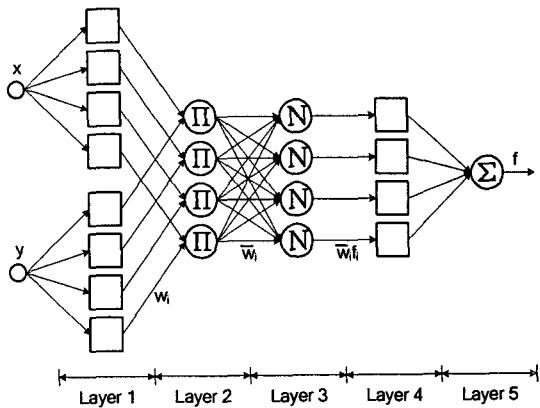
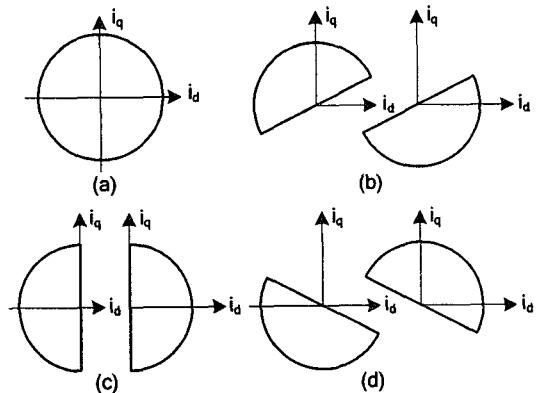


그림 3. 클러스터링 기반 뉴로-퍼지시스템
Fig. 3. Clustering based neuro-fuzzy system



(a) 정상모드
(b) T_3 과 T_4 의 고장
(c) T_1 과 T_2 의 고장
(d) T_5 와 T_6 의 고장

그림 5. d-q 상전류 벡터의 이상적인 경로
Fig. 5. Ideal trajectory of d-q phase current vector

3. 인버터 고장의 특성분석

3상 유도전동기 구동시스템은 그림 4와 같이 전원, 정류기, dc 링크 필터, 인버터, 제어기, 유도전동기의 구성요소들을 갖는다. 각각의 구성 요소에 대하여 발생할 수 있는 고장을 요약하면 다음과 같다.

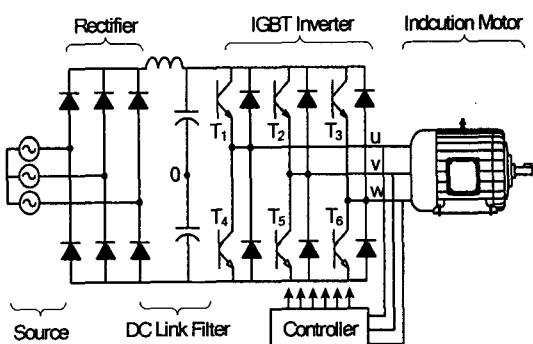
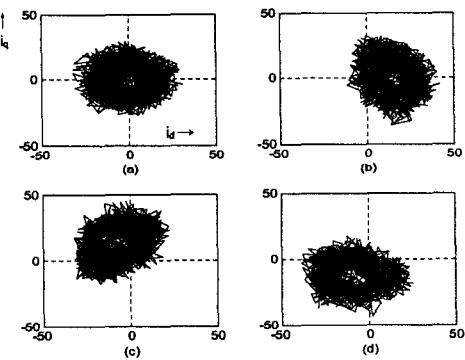


그림 4. 전동기 구동시스템의 구성도
Fig. 4. The simplified diagram for motor drive

- 1) 전원 및 링크 : 한 상 또는 상간의 단락 및 개방
- 2) 정류기 : 다이오드의 절연파괴
- 3) dc 링크 필터 : 커패시터의 절연파괴
- 4) 인버터 및 제어기 : 전력소자 및 제어 부의 고장
- 5) 유도전동기 : 전기, 기계적인 고장



(a) 정상모드
(b) T_2 의 고장
(c) T_4 의 고장
(d) T_6 의 고장

그림 6. 섭동 및 외란에 간섭된 d-q 상 전류 벡터
Fig. 6. Perturbed d-q phase current vector

본 논문에서는 인버터에 발생하는 고장 중에서 전력소자의 절연파괴와 제어부의 고장으로 인해 잘못된 구동신호의 발생에 관한 문제만을 고려한다. 즉, 두 가지 경우는, 전력용 스위치 소자의 단락회로는 일반적으로 단락보호장치를 가동시키므로 개방회로에 의한 고장으로 고려한다. 전력 스위치 소자의 고장은 그림 4에서 각각의 소자 $T_1 \sim T_6$ 에서 발생하며, 그들의 무작동은 유도전동기에 dc 토크 성분을 생성

클러스터링 기법을 이용한 3상 유도전동기 구동시스템의 고장진단

하게 한다. 그것은 유도전동기의 기계적 부분에 빠른 마모를 일으키고, 구성요소 수명에 영향을 끼치며, 또한, 유도전동기 구동시스템에 돌발적인 고장에 이르게 할 수 있다.

고장 검출 및 진단을 위한 신호는 3상 유도전동기의 고정자에 전력을 공급하는 각각의 상 전류로부터 가져온다. 이들은 스위칭 소자의 on-off 구동을 위해 제어부에서 사용하는 전류센서의 값이다. 센싱 신호는 두 가지 단계를 거쳐 인식 신호로 사용한다. 먼저, 3상 전류를 d-q 전류로 식 (1)에 의해 변환하는 것이고, 다음으로 식 (2)의 평균 전류벡터를 구하는 것이다. 그림 5는 인버터에 스위칭 소자의 고장이 발생하였을 때에 이상적인 d-q상 전류벡터의 경로를 보여준다. (a)는 정상 모드로 구동할 때에 횡축 d축 전류와 종축 q축 전류의 경로이며, (b), (c)와 (d)는 스위칭 소자 $T_1 \sim T_6$ 의 개방회로 고장이 발생하였을 때에 d-q상 전류벡터의 경로들을 보여준다. 여기서, 각 패턴들은 시각적으로도 손쉽게 구분할 수가 있으며, 고장의 종류를 판별하기가 쉽다는 것을 볼 수 있다.

그러나, 실제 구동시스템의 경우에는 해석적으로 규명하기가 어려운 많은 섭동 및 외란의 요인들을 갖는다. 또한, 그 섭동 및 외란들은 그림 6과 같이 d-q상 전류벡터의 형상을 보다 복잡하게 하여 패턴을 인지하기가 어렵게 한다. 여기서, 그림 6은 그림 5의 정상모드, T_2, T_4, T_6 의 고장 경로에 대응하는 경로를 보여준다.

또한, 그러한 d-q상 전류벡터는 인식 신호로 사용하기가 적절하지 않으므로, 본 논문에서는, 그림 7과 같이 정규분포를 갖는다고 가정한 각 주기의 평균 전류 벡터들을 가지고 고장 진단 및 인식을 수행하고자 한다. 그림 7에서 각각의 점들은 평균전류 벡터들의 기대 값을 의미한다.

4. 클러스터링 기법을 이용한 고장진단

전체 계통은 MATLAB과 SIMULINK를 사용하여 시뮬레이션을 하였다. 스위칭 소자, 유도전동기와 PWM 장치의 구성요소들은 MATLAB 라이브러리를 이용하였으며, 표 1은 각각의 파라미터 값들을 보여준다.

표 1. 모의실험 파라미터
Table 1. Parameters for simulation

Component name	Parameters
Asynchronous machine (squirrel cage type)	Poles=4, 5HP, 220V, 60Hz, stator: $R_s=0.435\Omega$, $L_s=2mH$ rotor: $R_r=0.816\Omega$, $L_r=2mH$ $M=69.31mH$, inertia factor=0.089km ²
Discrete 3-phase PWM generator(SPWM)	carrier frequency=1080, sample time=10e-6, modulation index=0.9
Universal bridge(IGBT)	snubber $R_s=1e5$, $C_s=\text{inf}$, $R_{on}=1e-3$

평균 전류벡터의 패턴은 실제적으로 발생 가능한 섭동과 외란의 요인들 고려하여 적절한 범위에서 랜덤한 섭동 및 외란을 인가하여 구하였으며, 그 결과는 그림 8에서 보여준다. 설정된 섭동 및 외란의 요인은 다음과 같다.

- 1) 전동기 파라미터들의 불확실성
- 2) 센서의 오프셋 및 외란
- 3) 한 주기 추출의 오차
- 4) 상전류의 불평형

그림 8에서, 섭동 및 외란은 기준 값에 대하여 상기한 1)~4)의 요인들을 $\alpha \cdot [-\epsilon_m, \epsilon_m]$ 범위에서 랜

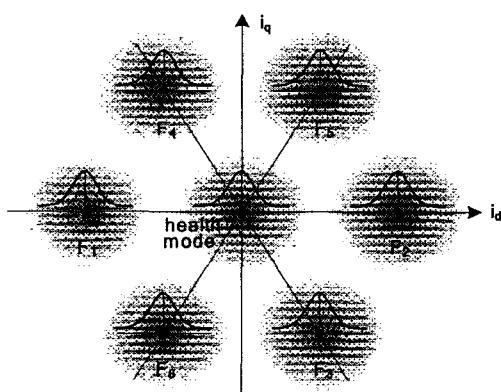


그림 7. 평균전류벡터들의 분포

Fig. 7. The distributions of mean current vectors

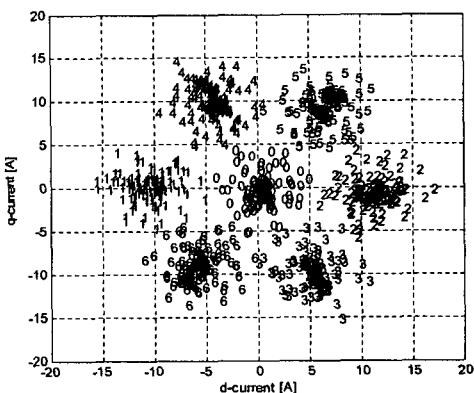
그림 8. 평균전류벡터들($\alpha = 1, \varepsilon_m = 10$)

Fig. 8. Mean current vectors

덤하게 발생시켰다. 여기서 ε_m [%]는 각각의 기준 값에 대한 편차를 의미하고 α 은 크기의 비이다. 전동기 파라미터들의 불확실에 대해서는 저항, 자기 및 상호 인더턴스, 마찰 계수에 대하여 표 1의 값에 $\varepsilon_m = 10$ [%] 정도의 편차를 주었고, 센서 오프셋은 기준 값의 10[%] 이내이며, 화이트 외란을 추가하였다. 한 주기 추출의 오차는 최대 0.0017[sec](17 샘플) 이내이다. 상전류 불평형은 각각의 상에 대해 기준 전류의 10[%] 편차 이내로 주었다. 결과적으로, 그림 8은 상기한 설정범위 이내에서 평균 전류벡터들을 도시한 것이다. 여기서, '0'은 정상상태를 보며 주며, '1~6'은 각각의 스위칭 소자 $T_1 \sim T_6$ 의 고장에 대한 평균 전류벡터를 보여준다. 여기서, 센서 오프셋이 분산에 가장 큰 영향을 주는 것을 알 수 있었다. 그림 9는 그림 8의 정상모드(0)와 고장모드(1~6)에 대하여 평균 전류벡터의 크기와 위상의 정규화된 분포를 보여준다.

훈련과 검사를 위한 데이터는 $\alpha = 0.5, 0.55, 0.6, \dots, 1$ 에 따라 11개의 집합을 구하였다. 제안한 고장 진단 방법을 적용한 결과는 그림 10에서 보여준다. 여기서, 클러스터링 중심들은 Yager의 방법에 의해 추정된 가우시안 소속함수들의 분산과 FCM(fuzzy clustering method) 방법에 의해 결정하였다[10]. 기존의 다른 알고리즘과 비교를 위하여, 전제부 파라미터들을 그리드 분할에 의해 구성한 기준의 뉴로-

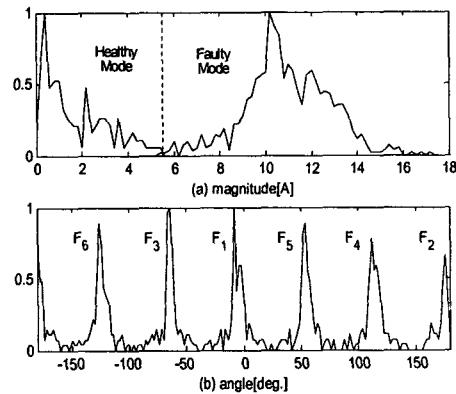
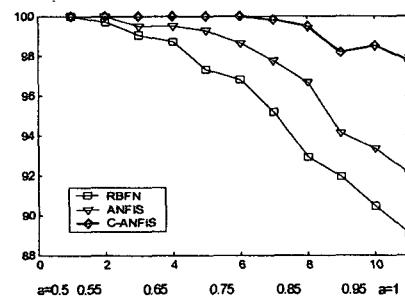


그림 9. 정규화된 평균전류벡터의 크기와 위상 분포

Fig. 9. Normalized distribution of mean current vectors

퍼시스템과 FCM에 의해 중심점을 구한 방사기저함수 네트워크(radial basis function network)에 대한 데이터 집합을 구하였다. 결과적으로, 그림 10에서, C-ANFIS로 표기된 제안한 방법은 비슷한 추론 망을 가진 다른 기법들 보다 좋은 성능을 가짐을 보여준다. 표 2는 각각의 알고리즘에 대한 설계사양을 나타낸다.

그림 11은 클러스터링 기반 뉴로-퍼지시스템을 사용하여 구한 소속함수를 나타냈다. 여기서, 클러스터(cluster)의 수는 7개로 설정하고 클러스터링 알고리즘을 수행하였다. 표 3은 퍼지 규칙들에 결론부의 최종 학습 파라미터들의 값을 나타냈다. 여기서, 1차 다항식의 가중치들은 거의 0에 근접한 값을 나타내므로, 출력들이 주로 상수항에 의해 출력패턴이 결정됨을 알 수 있다.

그림 10. 성능지표
Fig. 10. Performance index

클러스터링 기법을 이용한 3상 유도전동기 구동시스템의 고장진단

표 2. 알고리즘의 설계사양과 성능

Table 2. Specification and performance of algorithms

	RBFN	ANFIS	Proposed
Membership function		7, 7	7, 7
Nodes or rules	49	49	7
Learning epoch	100000	100	50
Training error	0	0	0
Worst error[%]	10.96	7.95	2.26

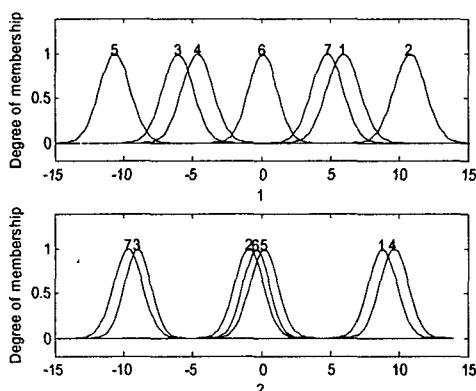


그림 11. 클러스터링 기반 소속함수

Fig. 11. Membership functions from clustering

표 3. 학습의 최종 파라미터

Table. 3. Final learning parameters

	p	q	a(상수)
규칙 1	2.60×10^{-6}	-2.83×10^{-7}	3
규칙 2	5.63×10^{-9}	5.66×10^{-7}	5
규칙 3	-5.58×10^{-7}	-5.19×10^{-7}	7
규칙 4	-2.05×10^{-7}	-1.16×10^{-7}	2
규칙 5	9.07×10^{-9}	-1.29×10^{-8}	1
규칙 6	5.90×10^{-7}	-4.33×10^{-7}	6
규칙 7	6.0×10^{-8}	-3.55×10^{-7}	4

5. 결 론

본 논문은 3상 유도 전동기 구동시스템 중에서 인버터의 고장 검출 및 진단 기법을 제시하였다. 입력 패턴의 소속함수를 구하기 위해 그리드 분할을 사용

할 경우 퍼지규칙의 수가 증가하는 문제점을 지니고 있다. 따라서 본 논문에서는 스캐터 분할 클러스터링 기법을 이용하여 학습시간과 퍼지규칙의 수를 효과적으로 감소시킬 수 있었다.

적용된 기법의 유용성을 보이기 위해 여러 불확실한 요소를 가진 3상 유도전동기 구동시스템에 대하여 모의 실험한 결과 기존의 방사기저함수만을 사용한 경우보다 8%, 그리드 분할 뉴로-퍼지시스템에 비해 5% 향상된 결과를 나타냈다. 또한 제안된 기법의 경우 기존의 방법에 비해 규칙의 수뿐만 아니라 계산속도 면에서도 향상된 결과를 나타냈다. 향후 실험에 의해 적용된 기법의 유용성을 보이고자 한다.

본 연구는 산업자원부의 지원에 의하여 기초전력공학공동연구소(R-2003-B-285) 주관으로 수행된 과제임.

References

- [1] A.G. Eason, R.L. Ribeiro, C.B. Jacobina, E.R.C. Silva, and AMN. Lima, Fault detection of open-switch damage in voltage-fed PWM motor drive systems, Power Electronics, IEEE Transactions, vol. 18, pp. 587-593, March 2003.
- [2] Z. Ye, and B. Wu, Simulation of electrical faults of three phase induction motor drive system, Power Electronics Specialists Conference, 2001, vol. 1, pp. 75-80, June 2001.
- [3] P.J. Chrzan, and R. Szczesny, Fault diagnosis of voltage-fed inverter for induction motor drive, ISIE '96, Proceedings of the IEEE International Symposium, vol. 2, vol. 2, pp. 1011-1016, June 1996.
- [4] J. Klima, Analytical investigation of an induction motor drive under inverter fault mode operations, Electric Power Applications, IEE Proceedings, vol. 150, pp. 255-262, May 2003.
- [5] R. Peuget, S. Courtine and J.P. Rognon, Fault Detection and Isolation on a PWM Inverter by Knowledge-Based Model, IEEE Transactions on Industry Applications, vol. 34, no.6, Nov/Dec 1998.
- [6] Sung-Suk Kim, Keun-Chang Kwak, Jeong-Woong Ryu, Myung-Ceun Chun, A Neuro-Fuzzy Modeling using the Hierarchical Clustering and Gaussian Mixture Model, KFIS, vol. 13, no. 5, pp. 512-519, 2003.
- [7] Sung-Suk Kim, Keun-Chang Kwak, Jeong-Woong Ryu, Myung-Ceun Chun, A Neuro-Fuzzy System Modeling using Gaussian Mixture Model and Clustering Method, KFIS, vol. 12, no. 6, pp. 571-578, 2002.

- [8] J. S. R. Jang, ANFS: Adaptive Network-based Fuzzy Inference System, IEEE trans. on System, Man, and Cybernetics, vol. 23, no. 3, pp. 665–685, 1993.
- [9] J-S. R. Jang, C.T. Sun., E. Mizutani, Neuro- Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence, Prentice Hall, 1997.
- [10] R. R. Yager, D. P. Filev, Generation of Fuzzy Rules by Mountain Clustering, Journal of Intelligent and Fuzzy System, vol. 2, pp. 209–219, 1994.

◇ 저자소개 ◇—————

박장환(朴長煥)

1967년 9월 5일 생. 1991년 충북대학교 전기공학과 졸업. 1993년 충북대학교 대학원 전기공학과 졸업(석사). 1999년 동 대학원 졸업(박사). 2001년 ~ 현재 충주대학교 정보제어공학과 계약교수(BK21).

김승석(金承石)

1972년 12월 19일 생. 1998년 충주대학교 전기공학과 졸업. 2002 충북대학교 전기공학과 졸업(석사). 현재 충북대학교 전기공학과 박사과정.

이대종(李大鍾)

1969년 2월 25일 생. 1995년 충북대학교 전기공학과 졸업. 1997년 충북대학교 전기공학과 졸업(석사). 2002년 충북대학교 전기공학과 졸업(박사). 2003년 ~ 2004년 컴퓨터정보통신연구소 연구원. 2004년 ~ 현재 Jointed university of Alberta as a postdoctoral.

전명근(全命根)

1964년 7월 17일 생. 1987년 부산대학교 전자공학과 졸업. 1989년 한국과학기술원 전기 및 전자공학과 졸업(석사). 1993년 한국과학기술원 전기 및 전자공학과 졸업(박사). 1993년 ~ 1996년 삼성전자 자동화연구소 선임연구원. 2000년 ~ 2001년 University of Alberta 방문교수. 1996년 ~ 현재 충북대학교 전기전자컴퓨터공학부 교수.