

유효 주파수 선택과 선형판별분석기법을 이용한 유도전동기 고장진단 시스템

Induction Motor Diagnosis System by Effective Frequency Selection and Linear Discriminant Analysis

이대종 · 조재훈 · 윤종환 · 전명근*

Dae-Jong Lee, Jae-Hoon Cho, and Myung-Geun Chun

충북대학교 제어로봇공학과 컴퓨터정보통신연구소

요 약

본 논문에서는 3상 유도전동기의 고장진단을 수행하기 위해 상호정보량과 선형판별분석기법에 기반을 둔 진단 알고리즘을 제안한다. 실험 장치는 유도전동기 구동의 기계적 모듈과 고장신호를 구하기 위한 데이터 획득 모듈로 구성하였다. 제안된 방법은 취득된 전류신호를 DFT에 의해 주파수 영역으로 변환한 후 분산정보를 이용하여 고장상태별로 차별성이 큰 순서대로 유효 주파수 성분을 추출한다. 다음 단계로 선택된 주파수 성분에 대해서 선형판별분석기법을 적용하여 고장상태별 특징들을 추출한 후 k-NN 분류기에 의해 유도전동기의 상태를 진단하게 된다. 제안된 방법의 타당성을 보이기 위해 다양한 조건하에서 실험한 결과 기존방법에 비하여 우수한 결과를 나타냈다.

키워드 : 고장진단, 선형판별분석기법, 상호정보량, 유도전동기

Abstract

For the fault diagnosis of three-phase induction motors, we propose a diagnosis algorithm based on mutual information and linear discriminant analysis (LDA). The experimental unit consists of machinery module for induction motor drive and data acquisition module to obtain the fault signal. 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 mutual information. As the next step, feature extraction is performed by LDA, and then diagnosis is evaluated by k-NN classifier. The results to verify the usability of the proposed algorithm showed better performance than various conventional methods.

Key Words : Fault Diagnosis, LDA, Mutual information, Induction motor

1. 서 론

산업발달과 더불어 산업현장에서 전동기의 수요는 매년 증가하고 있다. 그 중에서도 유도전동기는 구조적으로 간단하고 견고할 뿐만 아니라 저렴하기 때문에 산업용, 가정용 전동기로써 가장 널리 사용되고 있다. 이러한 유도전동기가 가동 중 갑작스런 고장에 의해 구동기능을 상실할 경우 시스템 전체의 마비로 이어져 치명적인 경제적 손실을 초래하게 된다. 따라서 전동기의 고장상태를 미리 예측하여 사고를 미연에 방지할 수 있는 유지보수의 측면이 강조되고 있으며, 전동기의 고장시 적절한 판단은 고장 또는 수명 예측과 더불어 중요한 부분으로 인식되고 있다.

유도전동기의 고장을 진단하기 위해 진동신호를 이용하

는 방법과 전류의 신호특성을 분석하여 진단하는 방법 등이 사용되고 있으나 최근에는 데이터 취득의 편리성과 고장상태간의 특성분석이 용이한 전류신호를 이용하는 MCSA (motor current signal analysis)이 주로 사용된다[1][2]. 이러한 MCSA 검출방법에 의해 전류신호를 취득한 후 진단을 위해 사용되는 유도전동기의 고장상태를 효과적으로 표현할 수 있는 특징추출 기법이 요구된다. 특징벡터 추출기법에는 Park 변환에 의해 d-q 패턴을 추출하는 방법[3][4], 웨이블렛 기법을 이용한 전류신호의 시간-주파수 특징을 추출하는 방법 등이 적용되고 있다[5][6]. 그러나 d-q 패턴의 경우 다양한 고장상태별로 고유의 패턴을 얻기가 어렵고, 노이즈가 존재하는 환경 하에서 고장패턴을 분류하는데 어려움이 있다. 또한, 웨이블렛에 의해 구해진 특징은 부하 변동에 의해 민감한 특성을 보임으로, 부하 또는 속도가 변화는 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 비선형특성을 갖는 데이터에 대해서는 최적의 변환행

* 교신저자

접수일자 : 2010년 4월 3일

완료일자 : 2010년 4월 30일

감사의 글 : 본 연구는 지식경제부의 지원에 의하여 기초전력연구원(2009T100100504) 주관으로 수행된 과제임.

를 구할 수 없는 문제점을 지니고 있다[7].

현재까지 유도전동기 고장진단을 위하여 입력전류의 주파수 특성을 분석하는 특징추출방법이 가장 널리 적용되고 있다[8]. 또한 FPGA나 DSP에 주파수성분을 고려한 고장진단 알고리즘을 구현하여 전기자동차의 전기 구동계통의 진단을 수행하는 연구도 시도되고 있다[9][10]. Thomson의 연구에 의하면, 유도 전동기는 고장상태별로 고유의 특정 주파수가 발생하는 것을 다양한 각도에서 해석하였다[11]. 그러나 주파수 기반의 특징추출 기법을 실시간 고장진단 시스템에 적용하기 위해서는 우세한 주파수 성분들의 선택이 반드시 수행되어야 한다. 즉, 입력전류에 대해 DFT(Discrete Fourier Transform)를 적용하여 주파수 성분들에 대한 정보(크기)를 산출하는데, 이 경우 대규모 입력차원을 갖는 모든 주파수 성분들을 고려하여 실시간 진단시스템을 구현 하는 데는 한계가 있다.

이러한 한계를 해결하기 위하여 Casimir 등은 푸리에 변환에 의해 얻어진 주파수 성분들에 대해서 SBS(Sequential Backward Selection) 기법에 의해 고장상태별로 효과적인 특징을 추출한 후 거리유사도에 의해 진단을 하는 방법을 제안하였으나, SBS 기법은 반복연산에 의해 특징을 추출함으로 다른 선택기법에 비해 계산속도가 매우 느린 단점을 가지고 있다[12].

본 논문은 상호정보량을 이용한 주파수성분의 속성선택 및 선형판별분석기법(LDA:Linear Discriminant Analysis)을 이용한 유도전동기 고장진단 시스템을 제안한다. 제안된 방법은 취득된 전류신호를 DFT(Discrete Fourier Transformer)에 의해 주파수 영역으로 변환한 후 상호정보량을 이용하여 고장상태별로 차별성이 큰 순서대로 주파수 성분을 추출한다. 다음 단계로 선택된 주파수 성분들에 대해서 선형판별분석기법을 적용하여 고장상태별 특징들을 추출한다. 또한, 계산속도를 향상시키고 메모리의 양을 줄이기 위해 퍼지 클러스터링(FCM : Fuzzy C-Means) 기법을 이용하여 고장상태별 대표 특징점들을 기준특징점으로 사용하였다. 진단단계에서는 선형판별분석기법에 의해 추출된 검증특징과 퍼지 클러스터링기법에 의해 구축된 기준벡터와의 유클리디언 거리비교에 의해 진단이 이루어진다.

본문의 내용은 2장에서는 제안된 유도전동기 진단알고리즘에 대해 설명한다. 3장에서는 실험 및 결과에 대하여 설명하고, 4장에서 결론을 맺는다.

2. 상호정보량 기법과 선형판별분석기법에 의한 유도전동기 고장진단

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 주파수 차원을 축소한 후 LDA에 의해 고장상태별 특징을 추출한다. 또한, 계산속도를 향상시키고 메모리의 양을 줄이기 위해 퍼지 클러스터링기법을 이용하여 고장상태별 대표 특징점들을 기준특징점으로 사용하였다. 진단단계에서는 선형판별분석기법에 의해 추출된 검증특징과 퍼지 클러스터링기법에 의해 구축된 기준벡터와의 유클리디언 거리비교에 의해 진단이 이루어진다.

단 이 이루어진다.

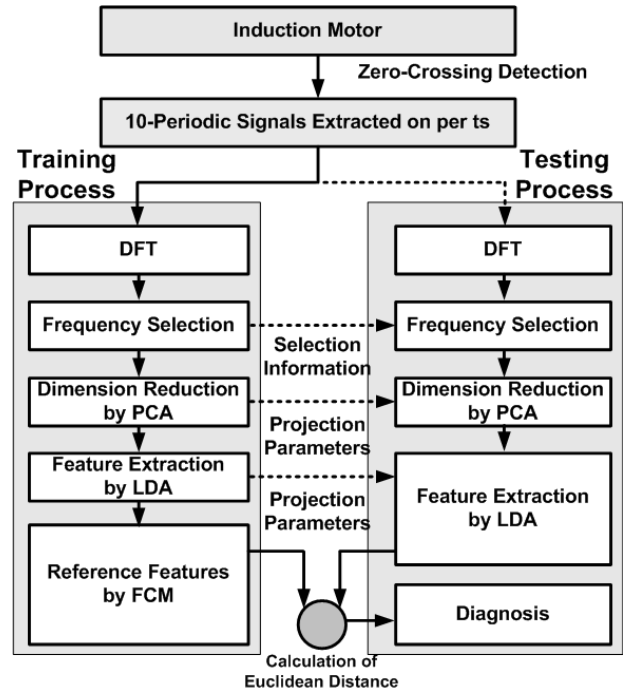


그림 1. 제안한 진단 알고리즘의 구성도

Fig. 1. The configuration for the proposed diagnosis algorithm.

2.1 상호정보량을 이용한 주파수 성분의 속성선택 기법

속성선택문제에서 주요한 피쳐들은 출력에 대하여 중요한 정보들을 많이 포함하고 있고 반대로 그렇지 못한 속성들은 출력에 관해 적은 정보들을 포함한다. 분류 문제를 해결하기 위해서는 입력 속성에서 가능한 한 많은 정보들을 포함하도록 속성들을 선택 하여야한다. 이런 목적을 달성하기 위해 랜덤한 변수들의 정보를 측정하는 새논의 정보이론에서는 엔트로피(Entropy)와 상호정보량을 소개하였다. 기본적으로 엔트로피는 랜덤 변수들의 무질서도(uncertainty)를 측정하는 것이다. 만약 랜덤변수 X 가 $p(x) = \Pr\{X=x\}, x \in \lambda$ 의 소스알파벳 λ 을 가진다면 X 의 엔트로피는 아래 식 (1)과 같이 계산된다.

$$H(X) = - \sum_{x \in \lambda} p(x) \log p(x) \quad (1)$$

두 개의 랜덤 변수 X 와 Y 의 결합 엔트로피(joint entropy)는 아래 식 (2)로 계산될 수 있다.

$$H(X, Y) = - \sum_{x \in \lambda} \sum_{y \in \delta} p(x, y) \log p(x, y) \quad (2)$$

위 식(2)에서 $p(x, y)$ 는 X 와 Y 의 결합확률밀도함수(joint probability density function)이다. 또한, Y 를 알고 있을 때의 X 의 엔트로피는 식 (3)으로 계산될 수 있다.

$$H(X|Y) = - \sum_{x \in \lambda} \sum_{y \in \delta} p(x, y) \log p(x|y) \quad (3)$$

X 와 Y 의 공통의 정보량은 두 변수 사이의 상호정보량으로 정의 될 수 있고 아래 식 (4)로 계산될 수 있다.

$$I(X;Y) = \sum_{x \in \lambda} \sum_{y \in \delta} p(x,y) \log \frac{p(x,y)}{p(x) \cdot p(y)} \quad (4)$$

본 논문에서는 유도전동기의 전류신호를 취득한 후 DFT에 의해 주파수 공간으로 변환한 후, 상호정보량을 이용하여 고장상태별로 차별성이 큰 순서대로 주파수 성분을 선택적으로 추출한다. 고장진단을 위해 연속적인 주파수 속성을 F, 고장상태를 나타내는 클래스를 C하면 속성과 클래스간의 상호정보량은 다음과 같이 정의 된다.

$$I(F;C) = \sum_{f \in \lambda} \sum_{c \in \gamma} p(f,c) \log \frac{p(f,c)}{p(f) \cdot p(c)} \quad (5)$$

상호정보량 $I(F;C)$ 이 클수록 속성 F 가 클래스 C 에 대해 많은 정보를 포함하는 것으로 정의되고 작으면 작을수록 속성 F 가 클래스 C 에 대해서 작은 정보를 포함하는 것으로 간주할 수 있다. 클래스에 대해 정보를 많이 포함한 속성을 선택함으로써 확률적으로 분류기의 성능을 우수하게 할 수 있고, 적은 정보량을 포함한 속성들을 제거함으로써 노이즈나 잘못된 데이터에 의한 분류기의 오차를 줄일 수 있다.

본 논문에서는 DFT를 출력 값들의 각 속성 값들을 평균을 이용하여 1과 0으로 정규화 시켜 각 속성과 클래스간의 상호정보량을 계산하고 높은 순으로 정리하여 각 속성들의 중요도를 평가하였다.

2.2 전류신호의 주파수변환과 유도전동기 고장진단

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 이산푸리에변환계수라고 불리고, DFT 계수 $X(k)$ 역시 N-점 수열이다. N점의 디지털 신호의 DFT를 정의하면 다음과 같다.

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi n/N}, 0 \leq n \leq N-1 \quad (6)$$

역으로 이산신호 스펙트럼에서 이산수열을 얻으려면 다음과 같은 역 이산 푸리에 변환으로 표현된다.

$$x[n] = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j2\pi k/N}, 0 \leq k \leq N-1 \quad (7)$$

식(6)을 이용하여 유도전동기의 전류신호를 주파수 공간으로 변환한다. 전류신호를 주파수로 변환 한 후 상호정보량을 이용하여 고장상태별로 상호정보량이 큰 주파수 성분을 선택한 후 선택된 주파수 성분을 이용하여 선형판별분석 기법을 이용하여 특징을 추출하게 된다.

선형판별분석(LDA)은 분류를 위해 최적의 사영을 찾는 방법중의 하나이다. 사영된 분산을 최대화하는 사영을 찾기 보다는 LDA는 BCS(between-class scatter)행렬과 WCS(within-class scatter)행렬의 비가 최대가 되는 사영행렬 W 를 찾는 것이다. 결과적으로 분류는 사영된 공간에서 간소화되어진다. 일반적으로 선형판별분석기법을 이용하여 분류하고자 할 경우 최적의 사영행렬 W 를 계산하기 전에 WCS행렬이 정칙이 되도록 주성분분석(PCA)기법을 이용하여 입력신호를 저차원 공간으로 사영한다. 본 논문에서 선형판별분석기법을 이용하여 특징추출하는 과정을 설명하기 위해 주파수 성분의 차원축소에 사용되는 PCA와 특징추출을

위해 사용되는 LDA에 대하여 설명한다[13][14].

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 (8)과 같이 선택된 p 개의 주파수 정보에 대한 평균을 구한다.

$$m = \frac{1}{P} \sum_{i=1}^P x_i, \quad x_i \in R^{1 \times n} \quad (8)$$

[단계 2] 학습용 주파수 정보에 대한 공분산행렬을 구한다.

$$\Omega = \overline{XX^T} \quad (9)$$

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

[단계 3] 식 (10)에 의해 계산된 공분산에 대한 n 개의 고유값과 n 개의 고유벡터를 구한다.

$$\Omega v_i = \lambda_i v_i \quad (10)$$

[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 (11)에 의해 산출한다. 식 (11)에서 알 수 있는 바와 같이 입력신호에 대한 특징벡터는 공분산에 대한 고유벡터를 이용하여 PCA변환된 공간으로 투영함으로써 얻을 수 있다.

$$z_i = V^T(x_i - m)^T, \quad i = 1, 2, \dots, P \quad (11)$$

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

$$z'_i = V^T(x'_i - m)^T \quad (12)$$

LDA기법은 클래스내의 분산을 나타내는 WCS(within-class scatter)행렬 S_W 와 클래스간 분산을 나타내는 BCS(between-class scatter)행렬 S_B 의 비율이 최대가 되는 행렬을 구하고, 이 행렬을 이용하여 선형변환하는 기법이다. 즉, PCA기법과 같이 투영된 분산을 최대화하는 투영을 찾기 보다는 클래스간의 차별성을 극대화시키는 최적의 투영행렬을 구한 후, 투영행렬을 이용하여 입력신호를 선형변환한다. LDA기법에 의한 특징추출과정을 단계별로 살펴보면 다음과 같다.

[단계 1] PCA에 의해 차원 축소된 신호 Z_i 에 대해 식 (13) 및 식 (14)에 의해 BCS 행렬인 S_B 와 WCS 행렬인 S_W 를 구한다.

$$S_B = \sum_{i=1}^c n_i (m_i - m)(m_i - m)^T \quad (13)$$

$$S_W = \sum_{i=1}^c \sum_{x \in C_i} (x - m_i)(x - m_i)^T \quad (14)$$

여기서, n_i 는 i 번째 클래스 C_i 에서의 데이터 수이며, m_i 는 i 번째 클래스 C_i 내의 평균값을 나타내며, m 은 전체 클래스의 평균값을 의미한다.

[단계 2] 식 (15)와 같은 WCS행렬에 대한 BCS행렬의 비를 최대화하는 정규직교행렬을 갖는 최적의 사영행렬 W 를 식 (16)에 의해 구한다.

$$W = \operatorname{argmax}_W \frac{|W^T S_B W|}{|W^T S_W W|} \quad (15)$$

$$= [w_1, w_2, \dots, w_p]$$

$$S_B w_i = \lambda_i S_W w_i, \quad i = 1, 2, \dots, P \quad (16)$$

[단계 3] 학습신호 Z_i 에 대한 특징벡터 T_i 를 구한다.

$$T_i = W^T z_i = W^T v_i^T (x_i - m) \quad (17)$$

식 (17)에서 알 수 있는 바와 같이 선형판별분석을 위해서는 우선 PCA기법에 의해 입력신호를 저차원으로 축소한 후, 산출된 특징벡터 Z_i 를 최적의 투영행렬 W 에 의해 LDA공간으로 투영시킨다. 일반적으로 학습신호의 수(P)가 신호의 길이(N)보다 적을 경우 WCS행렬 S_W 는 항상 특이행렬이 된다. 이것은 사영행렬을 적당히 선택하지 않는다면 사영된 WCS행렬은 영이 될 수 있음을 의미한다. 따라서 이러한 문제점을 해결하기 위하여 PCA기법을 이용하여 입력신호를 저차원공간으로 축소한 후 선형판별분석을 수행한다.

[단계 4] 진단하고자 하는 입력신호를 LDA기법에 의해 특징을 추출한다.

$$T'_i = W'^T z'_i = W'^T v_i^T (x'_i - m) \quad (18)$$

2.3 FCM을 이용한 대표 특징 선택

효과적으로 유도전동기의 이상 진단을 위해서는 진단하고자 하는 입력 데이터와 구축된 기준 모델과의 비교에 의해 이루어짐으로 신뢰성 높은 기준 모델의 구축이 무엇보다도 중요한 요소로 작용하고 있다. 즉, 실측한 모든 데이터를 기준모델로서 고려한 경우 대용량 데이터로 인한 메모리의 한계 및 처리속도가 저하되는 문제점이 발생한다. 이러한 문제점을 해결하기 위한 한 방법으로서 모든 데이터를 사용하지 않고 신뢰성 높은 기준 모델을 선택하는 것이 중요하다. 본 연구에서는 유도전동기의 상태별 대표특징들을 나타내는 기준모델을 구축하기 위하여 퍼지의 소속도 개념을 도입한 클러스터링 기법인 FCM(Fuzzy C-Means)을 응용하였다. FCM 클러스터링 알고리즘의 클러스터 중심을 찾는 순서는 다음과 같다[15].

[단계 1] 취득하고자 하는 대표점의 수 즉, 클러스터의 수 c ($2 \leq c \leq n$)를 정하고, 초기 분할행렬 $U^{(0)}$ 를 초기화한다. 분할행렬에 할당될 소속정도의 값 μ_{ik} 는 다음 식을 만족한다.

$$\mu_{ik} = \mu_{Ai}(x_k) \in [0, 1] \quad (19)$$

[단계 2] 각 단계에서 데이터 x 와 초기 분할행렬값 u 를 이용하여 대표 특징의 중심 $v_i^{(r)}$ 을 계산한다.

$$v_{ij} = \frac{\sum_{k=1}^n \mu_{ik}^m \cdot x_{kj}}{\sum_{k=1}^n \mu_{ik}^m} \quad (20)$$

[단계 3] [단계 2]에서 계산된 대표 특징들의 중심값과 데이터 x 와의 거리값 d 에 의하여 분할 행렬 $U^{(r)}$ 을 다음과 같이 갱신한다.

$$\mu_{ik}^{(r+1)} = \left[\sum_{j=1}^c \left(\frac{d_{jk}^{(r)}}{d_{jk}^{(r+1)}} \right)^{2/(m-1)} \right]^{-1} \quad (21)$$

여기서, m 은 퍼지화 정도를 나타내는 퍼지 수로써 일반적으로 2를 이용한다. 또한, d_{jk} 는 p 차원을 갖는 j 번째 데이터 x_j 와 k 번째 대표 중심값 v_k 와의 유클리디안 거리값을 의미한다.

$$d_{jk} = d(x_j, c_k) = \left[\sum_{i=1}^p (x_{ji} - v_{ki})^2 \right]^{-1} \quad (22)$$

[단계 4] 다음과 같이 목적함수를 계산한 후, 만약 $\|J(U^r, v^r) - J(U^{(r-1)}, v^{(r-1)})\| \leq \epsilon_1$ 이면 알고리즘을 종료하고 그렇지 않으면 [단계 2]로 가서 반복 수행한다.

$$J(U, c_1, c_2, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (23)$$

3. 실험 및 결과

3.1 실험장치 구성

유도전동기 고장진단을 위해 설치한 실험장치의 기본적으로 유도전동기 구동부분, 데이터 습득부분과 고장진단부분으로 구성되어 있다. 세부적으로 유도전동기 구동부분은 전동기구동부, 전동기, 안전장치, 다양한 전압표시장치, 전류센서와 진동센서의 구동회로, 그리고 전기적 브레이크 기능을 갖는 부하 시스템을 갖는다. 그림 2에서는 실험장치를 나타냈다. 그림 2에서 볼 수 있듯이 진단 실험시스템은 많은 추가 요소들을 가지고 있다. 먼저 그림 2의 좌측 상단에 있는 인버터는 인버터 구동을 위해 설치하였으며, 구동 전류의 불평형 및 변동을 위해 가변전압기와 가변저항기를 설치하였다. 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. 실험에 사용된 유도전동기는 220/380V 4극의 0.4[KW]이다.




그림 2. 실험장치

Fig. 2. 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 3. 유도전동기의 고장

Fig. 3. Faults of induction motors

고장데이터 중에서, 그림 3(a)에 보인 베어링 고장은 외곽 레일부분의 한 부위에 압착을 가하여 고장을 발생시켰다. 또한 그림 3(b)에 보인 회전자는 Zhongming 등이 실험한 방법과 같이 회전자의 편심에 드릴로 구멍을 내어 고장을 발생시켰다[6]. 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 20kHz로 설정하였으며, 따라서 한 주기 당 334개의 샘플을 취득하였다. 학습에 사용된 훈련데이터는 고장상태별로 부하를 무부하, 16kg·m로 2단계로 분류하여 고장상태별로 10주기를 갖는 100개의 데이터(부하상태 2 × 50샘플)를 취득하였다. 검증데이터는 고장상태별로 부하를 무부하, 0.04kg·m, 0.08kg·m, 0.12kg·m, 0.16kg·m로 5단계로 분류하여 고장상태별로 10주기를 갖는 250개의 데이터(부하상태 5 × 50샘플)를 취득하였다.

3.3 실험 결과

그림 54서는 정상 및 고장에 따른 전류 신호에 대해 샘플 데이터 신호를 나타냈다. 그림 4에서 알 수 있는 바와

같이 시간 데이터로만으로는 고장 상태별로 차별성을 찾는 데 어려움이 있다. 그림 5에서는 고장상태별 파워 스펙트럼을 나타냈다. 시간데이터와 달리 고장상태별로 파워스펙트럼의 특성을 분석할 수 있다. Bangura가 사용한 모델과 실측한 전류 파형의 주파수 공간의 주파수 성분은 공급 전압과 관련된 고조파(harmonics) 성분임을 나타내고 있으며 [16], 이들 주파수의 특징 형태는 공급 전압 파형의 왜곡에 의한 것으로 정상 및 고장에 따른 DFT한 결과의 공통적인 특징으로 기본 주파수인 60Hz의 홀수배에 해당하는 부분에서 상대적으로 피크치를 나타내는 것을 볼 수 있다.

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 60Hz의 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 있다. 저주파 뿐만 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 6에서는 본 논문에서 제안한 분산을 이용한 차별정도를 나타냈다. 그림 6에서 볼 수 있는 바와 같이 0.5[kHz]이내와 4[kHz]-5[kHz]사이에 클래스간 차별성이 큰 것으로 나타났다. 그림 7에서는 차별성이 큰 순서대로 x축에 해당하는 수 만큼 증가시키면서 진단율을 분석해 보았다. 그림 7에 사용된 알고리즘은 특징선택 후 DFT와 LDA를 수행한 결과를 나타냈다. 그림 7에서 보는 바와 같이 특징의 수를 35개 선택할 경우 진단율이 99.8%로 가장 높게 나타났다. 이는 전구간 주파수 성분을 고려한 경우의 진단율인 92.8%와 비교해 볼 때 매우 향상된 진단 성능을 나타냈다.




그림 4. 고장 상태별 전류 신호

Fig. 4. Current signals by fault type of induction motor

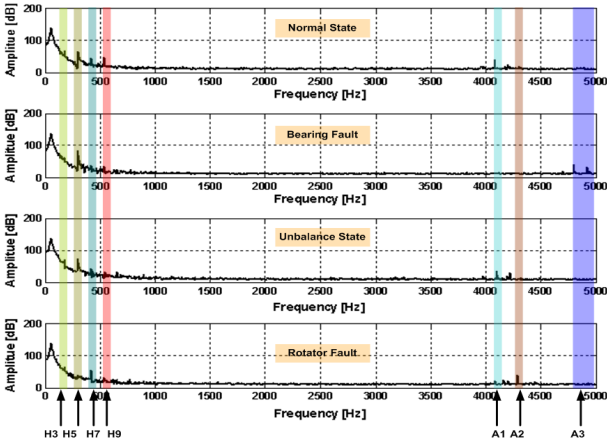


그림 5. 고장상태별 파워 스펙트럼

Fig. 5. Power spectrum according to fault type for induction motor




그림 6. 분산을 이용한 차별정도

Fig. 6. Discriminative factor calculated by variance

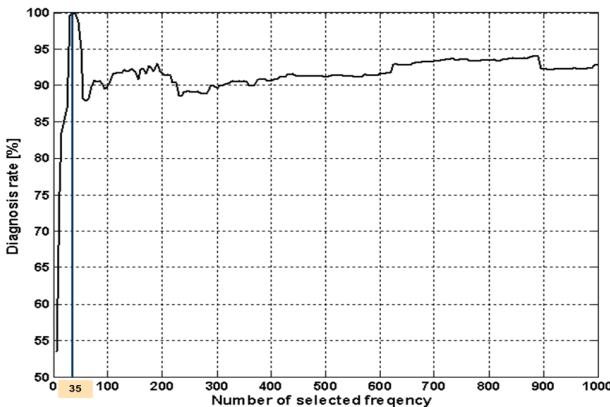


그림 7. 선택된 주파수 개수에 따른 진단율

Fig. 7. Diagnosis rate according to number of selected frequency components

그림 8에서는 주파수 성분을 35개 선택했을 경우 선택된 주파수 성분의 분포도를 나타냈다. 그림 8에서 보는 바와 같이 선택된 주파수 성분은 1[kHz]이내와 4[kHz]-4.5[kHz] 사이에 존재하고 있음을 확인할 수 있다. 표 2에서는 적용방법별 진단결과를 나타냈다. 표 2에서 H1은 정상, F1은 베어링고장, F2는 전압불평형, F3는 회전자고장을 각각 의미한다. 우선 PCA 방법은 차원이 65개 일 때 진단률이 66.2%로 나타났으며, PCA에 의해 차원 축소후에 적용된 LDA 방법은 차원이 3 일 때 진단률이 64.2%로 나타나 진단률이 매우 낮게 나타났다. 이는 시간영역에서 고장상태별 차별성이 크게 나타나지 않은 것에 기인한 것이라 분석된다. DFT+PCA 방법은 차원이 5 일 때 진단률이 82.6%로 나타났으며, DFT+LDA 방법은 92.8%로 시간영역에 비하여

DFT에 의한 주파수공간에서 차원을 축소한 경우 진단률이 향상됨을 확인할 수 있다.




그림 8. 선택된 주파수 성분의 분포도

Fig. 8. Distribution of selected frequency components

표 1에서는 적용방법별 진단결과를 나타냈다. 표 2에서 H1은 정상, F1은 베어링고장, F2는 전압불평형, F3는 회전자고장을 각각 의미한다. 우선 PCA 방법은 차원이 65개 일 때 진단률이 66.2%로 나타났으며, PCA에 의해 차원 축소 후에 적용된 LDA 방법은 차원이 3 일 때 진단률이 64.2%로 나타나 진단률이 매우 낮게 나타났다. 이는 시간영역에서 고장상태별 차별성이 크게 나타나지 않은 것에 기인한 것이라 분석된다. DFT+PCA 방법은 차원이 5 일 때 진단률이 82.6%로 나타났으며, DFT+LDA 방법은 92.8%로 시간영역에 비하여 DFT에 의한 주파수공간에서 차원을 축소 한 경우 진단률이 향상됨을 확인할 수 있다.

표 1. 적용방법별 진단결과

Table 1. Fault diagnosis result by each method

[unit : %]

Method	H1	F1	F2	F3	진단률
PCA	20.0	80.0	100	64.8	66.2
LDA	37.6	44.4	100	75.2	64.2
DFT+PCA	90.4	71.6	69.2	99.2	82.6
DFT+LDA	98.4	99.2	78.4	95.2	92.8
DFT+FS+PCA	92.8	98.4	85.6	98.9	93.9
DFT+FS+LDA	100	100	99.6	99.6	99.8
DFT+FS+LDA+FCM	100	100	99.6	99.6	99.8

DFT+FS+PCA(FS는 클래스간 차별성이 큰 주파수 성분을 선택을 의미)는 주파수 성분을 35개, PCA에 의한 차원 축소를 5개로 하였을 때 진단률이 93.9%로 나타났다. DFT+FS+LDA 방법은 주파수 성분을 35개, PCA에 의한 차원축소를 5개, LDA에 의한 특징을 3개 선택하였을 때 진단률이 99.8%로 나타나 매우 높은 진단성능을 나타냈다. 마지막으로 FCM에 의해 기준벡터를 생성 후 진단한 결과인

DFT+FS+LDA+FCM은 클러스터의 수를 그림 9에서 보는 바와 같이 인식률이 가장 우수하게 나타난 20개로 설정하였을 때 99.8[%]로 나타났다. DFT+FS+LDA+FCM 방법은 클러스터링 없이 고장진단을 수행한 DFT+FS+LDA와 동일한 결과를 나타내면서 고장상태별 기준벡터의 수를 100개에서 20개로 줄여줌으로써 계산속도의 향상과 임베디드 시스템 구현을 위한 저장메모리를 감소시킬 수 있는 장점이 있다. 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.




그림 9. 클러스터 수에 따른 진단율

Fig. 9. Diagnosis result according to number of cluster

4. 결론

본 논문에서는 클래스 내와 클래스 간의 분산정보를 이용한 주파수 성분의 선택적 추출기법과 선형판별분석기법에 의한 유도전동기 고장진단 시스템을 제안하였다. 실험결과, 제안방법은 진단률이 99.8[%]로 나타나 매우 높은 진단 성능을 나타냈다. 또한 FCM에 의해 계산속도의 향상과 임베디드 시스템 구현을 위한 저장메모리를 감소시킬 수 있는 방법을 제시하였다. 다양한 알고리즘과 비교분석한 결과 유도전동기 고장진단은 시간영역보다는 주파수 공간이 효과적임을 알 수 있다. 또한 고장상태별로 차별성이 큰 속성만을 선택한 후 고장진단 알고리즘을 적용하는 것이 효과적임을 확인할 수 있다.

참고 문헌

[1] 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.
 [2] Vilas N. Ghate, 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.
 [3] Fatiha Zidani, Demba Diallo, "A Fuzzy-Based Approach for Diagnosis of Fault Modes in a Voltage-Fed PWM Inverter Induction Motor Drive," *IEEE Trans., Industrial Electronics*, vol. 55, no. 2, pp. 586-593, 2008.
 [4] Nejari, M. H. Benbouzid, "Monitoring and diagnosis of induction motors electrical faults using a current Park's vector pattern learning approach," *IEEE Trans. Ind. Applications*, vol. 36, no.3, pp. 730-735, 2000.
 [5] 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, no. 3, pp. 417-423, 2003.
 [6] 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, pp. 1217-1228, 2003.
 [7] Achmad Widodo, and et al, "Combination of independent component analysis and support vector machines for intelligent faults diagnosis of induction motors," *Expert Systems with Applications*, vol. 32, no. 2, pp. 299-312, 2006.
 [8] Boqiang Xu, Liling Sun, Hui Ren, "A New Criterion for the Quantification of Broken Rotor Bars in Induction Motors", *IEEE Trans., Energy Conversion*, vol. 25, no. 1, pp. 100-106, 2010.
 [9] Bilal Akin, and et al, "DSP-Based Sensorless Electric Motor Fault-Diagnosis Tools for Electric and Hybrid Electric Vehicle Powertrain Applications," *IEEE trans., Vehicular Technology*, vol. 58, no. 6, pp. 2679-2688, 2009.
 [10] E. Cabal-Yepez, and et al, "FPGA-based Online Induction Motor Multiple-fault Detection with Fused FFT and Wavelet Analysis", *International Conf., Reconfigurable Computing and FPGAs*, pp. 101-106, 2009.
 [11] W. T. Thomson, M. Fenger, "Current signature analysis to detect induction motor faults," *IEEE Ind. Applicat. Magazine*, pp. 26-34, pp. 26-34, 2001.
 [12] 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.
 [13] M. Turk, A. Pentland, "Face recognition using eigenfaces", *IEEE Conf., on Computer Vision and Pattern Recognition*, pp.586-591, 1991.
 [14] P. N. Belhumeur, J. P. Hespanha, D. J. Kriegsmann, "Eigenfaces vs. Fisherfaces : recognition using class specific Linear Projection", *IEEE Trans. on Pattern Analysis and Machine Intell.*, vol. 19, no.7, pp. 711-720, 1997.

[15] Bezdec, J.C., *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.
 [16] J. F. Bangura, N. A. Demerdash, "Diagnosis and Characterization of Effects of Broken Bars and Connectors in Squirrel-Cage Induction Motors by a Time-Stepping Coupled Finite Element-State Space Modeling Approach," *IEEE Transactions on Energy Conversion*, vol. 14, no. 4, pp. 1167-1176, 1999.

저 자 소 개



이대종(Dae Jong Lee)
 1995년 : 충북대학교 전기공학과(학사)
 1997년 : 충북대학교 전기공학과(공학석사)
 2002년 : 충북대학교 전기공학과(공학박사)
 2004년 8월~2005년 7월 : University of Alberta Postdoc.

관심분야 : 바이오인식, 지능시스템, 패턴인식



조재훈 (Jae Hoon Cho)
 2002년 : 한밭대학교 제어계측공학과(학사)
 2004년 : 한밭대학교 제어계측공학과(공학석사)
 2005년~현재 : 충북대학교 제어로봇공학과 박사과정

관심분야 : 지능시스템, 퍼지제어기, 스마트그리드



윤종환(Jong Hwan Yoon)
 2009년 : 충북대학교 전기공학과(학사)
 2009년~현재 : 충북대학교 제어로봇 공학과(공학석사)

관심분야 : 임베디드 프로그래밍, 로봇공학, 영상처리



전명근(Myung Geun Chun)
 1987년 : 부산대학교 전자공학과(학사)
 1989년 : 한국과학기술원 전기 및 전자공학과(공학석사)
 1993년 : 한국과학기술원 전기 및 전자공학과(공학박사)
 1993년~1996년 : 삼성전자 자동화연구소 선임연구원
 2000년~2001년 : University of Alberta 방문교수
 1996년~현재 : 충북대학교 전자공학부 컴퓨터 정보통신 연구소 교수
 2008년~현재 : TTA PG505 의장
 2007년~현재 : ISO/IEC SC27 정보보호표준화전문위원

관심분야 : 패턴인식, Biometrics, 정보보호, 지능시스템