

클러스터링과 주성분 분석기법을 이용한 유도전동기 고장진단

Fault Diagnosis of Induction Motor Using Clustering and Principal Component Analysis

박찬원, 이대종, 박성무, 전명근

충북대학교 전기전자컴퓨터공학부

Chan-Won Park, Dae-Jong Lee, Sung-Moo, Park, Myung-Geun Chun

Chungbuk National University

School of Electrical and Computer Engineering

E-mail : mgchun@chungbuk.ac.kr

요 약

본 논문에서는 3상 유도전동기의 고장진단을 수행하기 위해 패턴인식에 기반을 둔 진단 알고리즘을 제안한다. 실험 장치는 유도전동기 구동의 고장신호를 얻기 위하여 구축하였으며, 취득된 데이터를 이용하여 진단 알고리즘을 구축하였다. 취득된 데이터 중에서 진단을 위해 사용될 훈련데이터는 퍼지 기반 클러스터링 기법을 이용하여 신뢰성 높은 데이터를 선택하여 고장별 신호를 추출하였다. 진단 알고리즘으로는 데이터를 주성분 분석기법을 적용하였으며, 최종 분류를 위해 Euclidean 기반 거리척도 기법을 이용하였다. 다양한 부하 및 고장신호에 대하여 제안된 방법을 적용하여 타당성을 검증하였다.

Key Words : 유도전동기, 고장진단, FCM(fuzzy c-means), PCA

1. 서 론

산업 현장에 널리 사용하고 있는 유도전동기들의 예기치 않은 고장은 전체 또는 일부 프로세스의 마비로 이어질 수 있으며, 이로부터 치명적인 사고와 경제손실을 초래할 수 있다. 최근, 이러한 고장들에 의한 사고를 미연에 방지할 수 있는 고장진단 기술이 유지보수의 측면과 더불어 중요한 부분으로 부각되고 있다.

기기의 고장진단의 방법은 모델기반 기법[1]과 지식기반 기법[2-7] 이 주류를 이룬다. 모델기반 기법들은 만약 기기를 포함하는 프로세스의 정확한 모델을 구할 수 있다면 매우 뛰어난 진단 시스템을 구축할 수 있다. 그러나, 일반적으로 비선형성(nonlinearity), 섭동(perturbation), 외란(disturbance) 등을 포함하는 전체 시스템의 정확한 모델을 구하기는 쉽지 않다. 그런 까닭에 최근에는 모델의 지식이 요구되지 않는 지식기반 기법을 적용한 많은 연구결과들과 적용 예들을 발표되고 있다. 지식기반기법으로는 전문가 시스템[2], 인공지능 및 통계적 방법[3] 등이 있다. 전문가 시스템은 실용적으로 적용하기 위해서 프로세스에 반영수정(mirror

modification)이 필요하고 규칙과 추론계도(reasoning tree)를 세울 수 있는 전문가가 존재해야 한다. 반면에, 인공지능 및 통계적 방법들은 모델링을 필요로 하지 않을 뿐만 아니라 전문지식이 필요 없으므로, 보다 폭넓은 적응성과 편리함을 가져다 준다. 이 방법은 정상과 고장조건에 초기 훈련 데이터에 의존성이 크어도 불구하고, 근래에 적당한 데이터를 얻을 수 있는 시뮬레이션 도구 및 연산 시스템의 발달로 비약적인 발전을 거듭하고 있다.

일반적으로 유도전동기의 온라인 고장진단은 진동신호 모니터링[4]과 MCSA(motor current signal analysis)[5-7]에 의해서 이루어진다. 과거에는 진동 모니터링에 기반을 둔 연구가 많이 이루어져 있지만, 산업 전반에 사용되고 있는 중소형 유도전동기에 이러한 진단 시스템을 구성하는 것은 센서 및 진단 시스템의 성능사양을 높이기 위해 많은 비용을 지불해야 하며 또한, 센서의 위치에 따른 성능변화와 전동기 지지 환경에 따른 구조적 진동의 유입 문제를 무시하기가 어렵다. 반면에, MCSA 검출방법을 이용하는 경우, 온라인 고장진단 과정이 간단하고, 절연상태를 제외한 대부분의 전기적·기계적 고장상태를 진단할 수 있으므로, 최근 이들에 관한 연구가 활발히 진행되고 있다.

MCSA에 신호검출과 인공지능 및 통계적 방법을 이용하여 유도전동기의 고장진단을 수행한 문헌들을 보면, Fenger[5]는 유도전동기의 다양한 고장들에 대한 스펙트럼 분석에 기반을 둔 MCSA의 성능을 분석한 결과를 보여 주었다. Nejari[6]와 Zidani[7]는 각각 인공신경망과 퍼지논리에 기반을 두고 진단 알고리즘을 설계하였으며, 시간영역에서 단지 입력전류의 Concordia 벡터들을 가지고 고장진단을 수행하는 방법을 제시하였다.

본 논문은 상기한 시간영역 상에서 MCSA와 통계적 패턴인식 기법을 이용하여 유도전동기의 온라인 고장진단 시스템을 구현하는데 목적을 둔다. 고장진단 수에 앞서 먼저 진단을 위한 구동 시스템을 제작한다. 이로부터 고장진단의 수행은 먼저, 다양한 부하상황과 주위환경에서 검출한 데이터 샘플들을 FCM (fuzzy c-means)을 이용하여 적절한 개수의 클러스터 중심 벡터들을 구한다. 이 벡터들로부터 주성분분석기법(PCA : Principal Component Analysis)를 적용하여 특징 추출을 한다. 최종 진단은 Euclidean 기반 거리척도 방법을 이용하였다.

본문의 내용은 2장에서는 제안된 진단 알고리즘을 설명하고, 3장에서는 실험 과정 및 결과에 대하여 설명한다. 4장에서는 결론을 맺는다.

2. 진단 알고리즘

유도전동기의 고장진단을 위하여 제안한 진단기법의 기본 구성도는 그림 2에서 보여준다. 그것은 전처리 과정, 특징추출과 분류 부분으로 구성된다.




그림 1. 제안된 알고리즘의 구성도

제안한 고장진단과정을 보면, 먼저, 훈련을 위해 반복 실험한 결과들은 동일한 정상 및 고장 환경에서 습득한 데이터들일 지라도 입력전원, 부하 등의 상태에 따라 습득 데이터들은 많은 차이를 보인다. 이러한 데이터들로부터 특징추출을 하기 위하여 우리의 연구에서는 FCM[8]을 이용하여 필요한 개수의 훈련 데이터를 각각의 클러스터 중심점으로 선택한다. 즉, 클래스 내부에서 클러스터링에 의해 원하는 개수의 중심점을 잡아주고 이들을 소위 부-클래스로 두어 특징추출은 독립적인 클래스로 놓고 진단 과정에서 각각의 부-클래스들을 클래스로 묶어 진

단을 수행할 것이다.

특징 추출은 PCA[8]를 이용한다.

PCA기법에 의한 특징추출 및 비교과정에 대하여 단계별로 설명하면 다음과 같다.

[단계 1] 측정된 학습용 전류신호를 1차원 열벡터로 변환한 후 식 (1)에 의해 전체 신호의 평균을 구한다.

$$m = \frac{1}{P} \sum_{i=1}^P x_i \quad (1)$$

[단계 2] 전류신호에 대한 공분산행렬을 구한다.

$$\Omega = \overline{XX^T}$$

$$\overline{X} = [\overline{x}_1, \overline{x}_2, \dots, \overline{x}_p],$$

$$\overline{x}_i = x_i - m \quad (2)$$

[단계 3] 식 (2)에 의해 계산된 공분산에 대한 고유값과 고유벡터를 구한다.

$$\Omega v_i = \lambda v_i \quad (3)$$

[단계 4] 고유벡터 v_i 를 고유값의 크기 순으로 나열한 후 학습신호 x_i 에 대한 특징벡터 z_i 를 구한다. 식 (4)에서 알 수 있는 바와 같이 입력신호에 대한 특징벡터는 공분산에 대한 고유벡터를 이용하여 PCA변환된 공간으로 투영함으로써 얻을 수 있다.

$$z_i = v_i^T (x_i - m) \quad (4)$$

[단계 5] PCA기법에 의해 입력전류(검증데이터)의 특징벡터를 산출한다.

$$z'_i = v_i^T (x'_i - m) \quad (5)$$

여기서, x'_i 은 인식하고자 하는 입력전류를 나타낸다. 최종적으로 추출된 특징 값들을 분류(classification)하기 위한 기법으로, Euclidean 기반 거리척도 방법을 적용하였다.

3. 실험 및 결과

3.1 고장시스템의 구성

유도전동기 고장진단을 위해 설치한 실험장치의 기본적으로 유도전동기 구동부분, 데이터 습득부분과 고장진단부분으로 구성되어 있다. 그림 2은 실험에 사용한 진단 시스템의 블록선도를 나타내며, 그림 3은 데이터 취득 및 진단을 위한 실험장치를 나타냈다. 또한 표 1에서는 본 실험에서 사용된 진단 시스템의 기본적 구성요소들의 사양을 나타냈다. 세부적으로 유도전동기 구동부분은 전동기구동부, 전동기, 안전장치, 다양한 전압표시장치, 전류센서와

진동센서의 구동회로, 그리고 전기적 브레이크 기능을 갖는 부하 시스템을 갖는다. 데이터 습득부에서는 3상 전류를 PC로 전송하기 위해 NI사의 PCI-6251 DAQ 보드를 사용하여 10kHz의 샘플링 데이터를 검출한다. 고장진단 부분은 PC 상에서 그림 4에서 보인 LabVIEW 7.1 프로그램을 이용하여 데이터를 취득하였다.

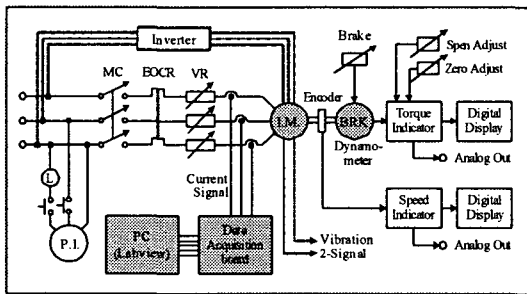


그림 2. 진단 시스템의 블록선도




그림 3. 실험장치

표 1. 진단 시스템의 사양

Component	Specification
Induction motor	0.4kW(1/2 HP), 220V, 60Hz 4p, 1700rpm, Efficient: 65%
Current sensor	Rating current: ±10A, Output: ±4V
Data acquisition	500Ks/s, 16bit, 4channel
Load equipment	Brake system of eddy current type
PC	Pentium 4, 2.8GHz

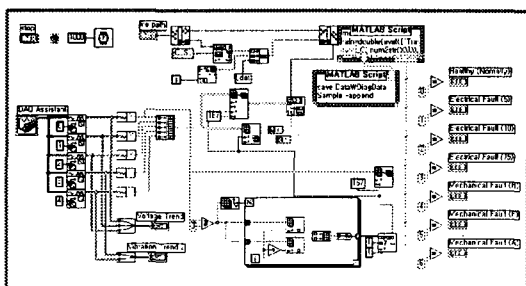



그림 4. 데이터 취득을 위한 Labview 프로그램

3.2 고장신호 분석 및 진단 결과


제안한 온라인 고장진단 기법의 검증하기 위하여 고장별 전류 신호를 취득하였다. 본 논문에서는 그림 5에서 보는 바와 같이 3상 유도전동기 고장의 원인으로 알려진 베어링 및 회전자 고장에 대하여 고려하였다. 베어링은 외곽 레일부분의 한 부위에 압착을 가하여 고장을 발생시켰다. 또한 회전자는 회전자의 편심에 드릴로 구멍을 내어 고장을 발생시켰다.

데이터 취득은 LabVIEW 상에서 영점교차점을 이용하여 1초마다 습득하는 1주기의 전류신호에 대하여 고장진단을 수행한다. 먼저, LabVIEW의 프로그램을 요약하면, DAQ 보드로부터 들어온 입력 데이터들을 주어진 일정 시간마다(1 초) 한 주기(10kHz에서 167개) 샘플을 검출하였다.

본 논문에서는 정상적인 상태, 베어링 고장상태, 회전자 고장상태에 대한 신호를 분류하고자 한다. 고장상태별로 부하를 무부하, 0.04 kg·m, 0.08 kg·m, 0.12 kg·m, 0.16 kg·m로 5단계로 분류하여 취득하였다. 각 고장상태별로 데이터를 150개(부하변동당 30개)를 취득하였다. 이 중에서 75개는 훈련데이터로서 나머지 75개는 검증데이터로 사용하였다. 그림 6에서는 각각의 고장상태별로 취득한 데이터의 파형을 나타냈다.




(a) 정상 베어링 (b) 고장 베어링




(c) 회전자 고장

그림 5. 유도전동기 고장 부위


그림 7에서는 클러스터링의 수 및 PCA에 의해 차원 감소된 특징벡터의 수에 따른 인식률을 나타냈다. 그림 7에서 보는 바와 같이 클러스터링의 수가 고장상태별로 65개 이고 축약된 특징벡터의 수가 20일 때 인식률이 96%로 나타났다. 이 결과로부터 전류신호만을 이용하여 유도전동기의 고장상태를 진단할 수 있음을 알 수 있다.



(a) 정상상태



(b) 베어링 고장



(c) 회전자 고장

그림 6. 고장상태별 전류 파형




그림 7. 클러스터링 및 특징벡터의 개수에 따른 인식률

4. 결론

본 논문에서는 FCM 클러스터링 기법, 주성분분석기법을 이용하여 특징추출을 하고, Euclidean 거리 척도를 이용하여 부하가 변동하는 유도전동기의 고장진단을 수행하는 알고리즘을 제안하였다.

먼저, 기존에 구성된 진단 시스템을 이용하여 실험 데이터를 추출한 후에 고장진단 특성 실험을 하였다. 적용된 방법의 타당성을 보이기 위한 시뮬레이션 결과를 비교 분석하였으며 결과적으로 온라인 진단 기법 시스템을 구축하였다. 온라인 고장진단은 실험을 위해 제작한 고장진단 시스템과 데이터 습득 보드, PC를 가지고 수행하였다. 실험한 결과, 클러스터링의 수가 고장상태별로 65개 이고 축약된 특징벡터의 수가 20일 때 인식률이 96%로 우수한 결과를 나타냈다. 이것이 100%의 결과를 보여주지 않는 것은 부하의 변동과 주변 상황 및 외관과 같은 데이터의 섭동에 의해 구분하기 어려운 샘플들이 형성되었기 때문일 것이다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초 전력공동연구소(R-2003-B-285) 주관으로 수행된 과제임

5. 참고 문헌

- [1] S. B. Dolines et al., "A curve interpretation and diagnosis technique for industrial process," IEEE Trans. Ind. Applicat., vol. 28, no. 1, pp. 261-267, January/ February 1992.
- [2] J. Sottile et al., "An overview of fault monitoring and diagnosis in mining equipment," IEEE Trans. Ind. Applicat., vol. 30, no. 5, pp. 1326-1332, September/ October 1994.
- [3] D. Dially et al., "Fault detection and diagnosis in an induction machine drive: a pattern recognition approach based on Concordia stator mean current vector," IEMDC'03, vol. 3, pp. 1448-1453, June 2003.
- [4] S. Wu, T. Chow, "Induction machine fault detection using SOM-based RBF neural network," IEEE Trans. Ind. Elect., vol. 51, no. 1, pp. 183-194, February 2004.
- [5] W. T. Thomson, M. Fenger, "Current signature analysis to detect induction motor faults," IEEE Ind. Applicat. Magazine, pp. 26-34, July/August 2001.
- [6] Nejari, M. H. Benbouzid, "Monitoring and diagnosis of induction motors electrical faults using a current Park's vector pattern learning approach," IEEE Trans. Ind. Applicat., vol. 36, no.3, pp. 730-735, May/June 2000.
- [7] Zidani et al., "Induction motor stator faults diagnosis by a current Concordia pattern-based fuzzy decision system," IEEE Trans. Energy Conversion, vol. 18, no. 4, pp. 469-475, December 2004.
- [8] Bezdec, J.C., Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press, New York, 1981.