

조건부 FCM과 방사기저함수네트워크를 이용한 유도전동기 고장 검출

Detection and Diagnosis of Induction Motor Using Conditional FCM and Radial Basis Function Network

김승석^{*}, 이대종^{***}, 박장환^{**}, 유정웅^{*}, 전명근^{*}

Sung-Suk Kim^{*}, Dae-Jeong Lee^{***}, Jang-Hwan Park^{**},
Jeong-Woong Ryu^{*}, Myung-Geun Chun^{*}

*충북대학교 전기전자컴퓨터공학부

**충주대학교 전기전자컴퓨터공학부

***충북대학교 컴퓨터정보통신연구소

*School of electrical and Electronic Engineering, ChungBuk National University

**School of electrical and Electronic Engineering, ChungJu National University

***Research Institute for Computer & Information Communication,
Chung-Buk National University

요약

본 논문에서는 유도전동기 고장진단을 위하여 계층적인 하이브리드 뉴럴네트워크를 제안하였다. 시스템의 입출력 데이터에 근거하여 패턴을 분류할 때 단계별 변환 및 분류 기법을 이용하였다. 제안된 방법에서는 실험에 측정된 전류값을 주기별로 주성분분석(PCA) 기법을 이용하여 입력차원을 축소한 후 이를 조건부 FCM으로 방사기저함수의 초기치를 최적화하는데 사용하였다. 이는 주성분분석이 가지는 특성을 이용하여 데이터의 특징을 나누었으며 이를 뉴럴네트워크의 학습 기능을 이용하여 고장검출 모델의 최종 성능을 개선하는 것이다. 이를 실제 계측된 유도전동기 데이터를 이용하여 실험한 결과 제안된 방법의 성능이 기존의 방법들에 비하여 우수함을 알 수 있었다.

Abstract

In this paper, we propose a hierarchical hybrid neural network for detecting faults of induction motor. Implementing the classifier based on the input and output data, we apply appropriate transform and classification method at each step. In the proposed method, after obtaining the current of state of motor for each period, we transform it by Principle Component Analysis(PCA) to reduce its dimension. Before the training process, we use the conditional Fuzzy C-means(FCM) for obtaining the initial parameters of neural network for more effective learning procedure. From the various simulations, we find that the proposed method shows better performance to detect and diagnosis of induction motor and compare than other methods.

Key words : Principle Component Analysis, Conditional Fuzzy C-means, Radial Basis Function Network, Fault detection

1. 서 론

산업 현장의 자동화와 더불어 전동기의 활용범위가 점차로 확대되어가고 있다. 특별한 용도의 전동기의 수요뿐만 아니라 일반적인 성능을 요구하는 경우 간단한 구조와 기계적 견고함 등으로 유도 전동기의 사용이 경제적으로 많은 장점을 가지고 있다[1][2]. 로봇 시스템 등의 특수한 전동기와는

달리 일반적인 산업현장의 설비에서 유도 전동기는 기계적 견고함과 신뢰성으로 전체 계통에 대한 동력을 공급하는 경우가 빈번하다. 이 경우 유도전동기의 고장은 유도전동기 자체의 문제뿐만 아니라 계통 전체의 치명적인 고장 또는 손실을 가져다 줄 수 있으므로 이를 미리 예측하고 사고를 미연에 방지할 수 있는 유지 보수 및 진단 방법이 활발히 연구되고 있다. 이 경우 유도전동기의 운전 휴무 시간에 점검을 통하여 문제점을 해결하는 방법과 운전 중 실시간으로 유도전동기의 상태를 고장 진단함으로써 사고를 방지하는 방법이 있다. 휴무 시간과는 달리 운전 중의 고장진단은 사람의 직접적인 또는 지속적인 감시가 어려운 부분이 존재한다. 따라서 센서를 통한 검출과 이를 자동으로 분류하여 고장진단을 실시할 수 있는 시스템이 필요하다. 유도전동기의 운전 중

접수일자 : 2004년 7월 19일

완료일자 : 2004년 11월 10일

감사의 글 : 본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2004-B-223)주관으로 수행된 과제임.

고장원인으로는 크게 기계적 결함과 전기적 결함으로 크게 나누어진다. 결합 신호를 검출하는 방법으로 직접적으로 센서를 부착하여 신호를 취득하는 방법과 간접적으로 전동기의 전류신호를 취득하여 분석하는 Motor Current Signature Analysis (MCSA) 방법 등이 있다[2]. MCSA 방법의 경우 전연상태 검출을 제외한 대부분의 상태를 검출할 수 있으므로 현재 널리 사용되고 있는 기법이다.

본 논문에서는 MCSA 검출 기법을 이용한 유도전동기의 기계적 결함 중에서 정상적인 상태와 회전자의 봉 파손, 회전자 축이 휘어진 경우, 정적 편심 상태, 동적 편심 상태, 베어링 고장 등 6가지의 유도 전동기의 운전 상태를 진단하고자 하였다.

먼저 유도 전동기 실험에서 고정자 전류를 MCSA 검출 기법을 이용하여 획득한 후 적절한 전처리 과정을 실시하고 이를 주성분분석(Principal Component Analysis :PCA)을 이용하여 입력 차원을 축소한다[3]. 이 입출력 데이터를 조건부 FCM(Conditional Fuzzy C-Mean)을 이용하여 초기 클러스터를 추정한 후 방사기저함수 네트워크(Radial Basis Function Network : RBFN)을 이용하여 학습하였다[4-6]. 각 단계별 과정을 거치면서 모델은 학습을 통하여 각 고장 상태에 대한 진단을 실시한다. 이를 실제 유도전동기에서 취득한 데이터를 통하여 모델 생성 및 검증을 실시함으로써 제안된 방법의 유용성과 잡음에 대한 강인성을 보이고자 한다.

2. 계층적 모델 최적화

2.1 주성분 분석을 이용한 특징벡터 추출

주성분분석은 서로 상관관계가 있는 벡터들이 존재할 때, 변이를 추정할 수 있는 새로운 벡터들을 생성하는 방법이다. 주어진 데이터에서 전체 평균과의 변이가 클수록 벡터가 가지는 정보가 많으며 변이가 큰 순서대로 변수들의 선형 결합을 이용하여 새로운 변수를 구한다[3].

만일 P 개의 $a \times b$ 사이즈를 가진 고차원 학습벡터 $N (= a \times b)$ 으로 1차원 학습 벡터로 변환하여 $X = \{x^1 \ x^2 \ x^3 \ \dots \ x^P\}$ 라고 가정하면 X 에 대한 평균은 다음과 같이 표현할 수 있다.

$$\bar{x} = \frac{1}{P} \sum_{i=1}^P x^i \quad (1)$$

식(1)에서 분산을 구하면 다음과 같다.

$$\begin{aligned} \bar{x}^i &= x^i - \bar{x} \\ \bar{X} &= [\bar{x}^1 \ \bar{x}^2 \ \dots \ \bar{x}^P] \end{aligned} \quad (2)$$

식(2)의 $N \times N$ 의 공분산 행렬은 다음과 같다

$$\Omega = \bar{X} \bar{X}^T \quad (3)$$

위의 공분산 행렬에서의 고유치(eigenvalue)와 고유벡터(eigenvector)는 다음과 같다.

$$\bar{X} \bar{X}^T v_i = \lambda v_i \quad (4)$$

식(4)에서, 학습신호 x_i 를 이용하여 고유벡터 v_i 를 얻음으로써 입력신호에 대한 특징벡터는 공분산에 대한 고유벡터이며 다시 말하여 PCA 공간으로 투영 변환이며 다음과 같이 표현할 수 있다.

$$z_i = v_i^T (x_i - \bar{x})^2 \quad (5)$$

실제 데이터의 크기가 클 경우 $N \times N$ 의 공분산 행렬에 대한 연산량 부담으로 다음과 같은 스냅샷(snap-shot) 방법으로 효과적으로 공분산 행렬의 고유벡터를 구할 수 있다.

$$\bar{X}^T \bar{X} (\bar{X}^T V) = \lambda (\bar{X}^T V) \quad (6)$$

여기서 V 을 \bar{X}^T 라고 하면 새로운 고유벡터는 다음과 같이 표현할 수 있다.

$$\bar{X}^T \bar{X} (V) = \lambda (V) \quad (7)$$

여기서 $\bar{X}^T = \bar{X}^{-1}$ 이므로 공분산 행렬 Ω 에 대한 고유벡터 V 는 다음과 같다.

$$\begin{aligned} V &= (\bar{X}^T)^{-1} V \\ &= (\bar{X} V) \end{aligned} \quad (8)$$

MCSA 검출을 통한 신호의 입력은 유도전동기의 주기전류이므로 직접적인 고장진단에 적용하는 것이 어려우므로 각 주기별 입력으로 전처리 과정을 거친 후 주성분 분석을 실시하여 추정되는 최대 변이(고유치) 순으로 고유벡터를 구성한다[2][3]. 즉 변이가 작을수록 시스템의 평균에 가까우며 변이가 클수록 시스템의 특성을 나타낸다. 이 경우 다차원의 행렬이 해당 시스템의 특성을 크기별로 나타내는 새로운 행렬로 구성이 됨으로써 특징이 크게 나타나는 입력들만을 사용하여 모든 벡터를 학습에 사용하여 발생하는 문제점을 해결할 수 있다.

2.2 조건부 Fuzzy C-mean을 이용한 학습 모델 초기화

뉴럴네트워크는 학습을 통하여 모델을 최적화한다. 이러한 학습 모델의 특징으로는 초기 학습 위치에 따라 학습 시간 및 수렴, 최종 모델의 성능 등이 달라진다. RBFN의 경우 다중 신경회로망과는 클러스터 개념을 기반으로 하는 방사기저함수를 사용함으로 네트워크의 학습 이전에 초기 클러스터 파라미터를 최적화할 경우 좋은 성능을 보인다. 일반적인 클러스터링 알고리즘인 FCM의 경우 단지 입력 데이터만을 고려하여 클러스터 파라미터를 추정하지만 조건부 FCM은 입력에 의한 출력이라는 인과관계를 고려하여 출력을 입력 클러스터 생성에 영향을 주도록 하였다[4][5]. 기본적인 FCM 알고리즘내의 소속도 추정은 다음과 같다.

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{ik}} \right)^{2/(m-1)}} \quad (9)$$

i 번째 중심(평균)에서의 j 번째 데이터와의 소속도를 중심과 데이터간의 거리 d 와 파지수 m 으로 표현한다고 하였을 때, 특정 데이터에 대한 모든 중심과의 소속도 합은 1이 된다. 하지만 조건부 FCM의 경우 다음과 같이 입력 데이터에 대한 클러스터의 추정에 결과 데이터 y_j 가 고려되어 위의 조건을 만족하지 않는다.

$$u_{ij} = \frac{f_{ij}(y_j)}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{ik}} \right)^{2/(m-1)}} \quad (10)$$

이 경우 클러스터 추정에 영향을 주는 소속함수 u_{ij} 로 인하여 출력까지 고려한 입력 클러스터가 생성된다. 이를 전체

알고리즘으로 보면 다음과 같다.

단계 1: 알고리즘 파라미터를 초기화 한다.

각 중심과 데이터 간의 소속도 U 를 $[0,1]$ 사이에서 식(10)의 조건에 만족하도록 임의로 설정한다.

$$\sum_{i=1}^c u_{ij} = f_{ij}(y_j), \quad \forall j = 1, \dots, n \quad (11)$$

단계 2: 퍼지 클러스터 중심 c_i 를 다음과 같이 계산한다.

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (12)$$

단계 3: 다음과 같이 목적함수를 계산한 후 종결조건을 만족하면 알고리즘을 끝내고 그렇지 않으면 단계 4로 간다.

$$J(U, c_1, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_j u_{ij}^m d_{ij}^2 \quad (13)$$

단계 4: 분할행렬 u_{ij} 를 식(10)과 같이 계산한 후 단계 2로 돌아간다.

본 논문에서는 조건부 함수 $f_{ij}(y_j)$ 의 결정에 기본 FCM의 소속도를 이용하였다. 즉 출력 데이터의 FCM 소속도를 입력 데이터 클러스터의 조건부 소속도로 이용함으로써 다중 FCM 알고리즘 형태로 구성하여 알고리즘의 개념과 복잡성을 해소하였다.

2.3 RBFN을 이용한 모델 최적화

뉴럴네트워크의 기본적인 형태인 다중 퍼셉트론과 유사한 RBFN는 그림 1과 같이 구성되어 있으며 다음과 같이 표현 할 수 있다[6][7].

$$f(x) = \sum_{i=1}^c R_i(x) w_i \quad (14)$$

다중 퍼셉트론의 경우 활성함수가 비선형의 선형 매핑을 위한 선형함수로 되어있는 반면 RBFN은 패턴의 클러스터 분류가 기본 형태이다. 즉 일반적인 RBFN은 식(15)와 같은 Gaussian 활성함수를 사용한다.

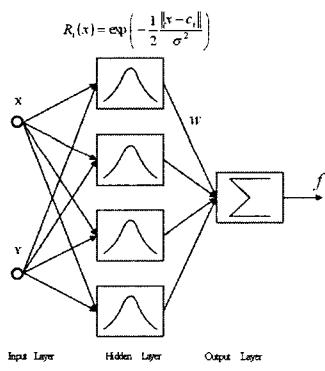
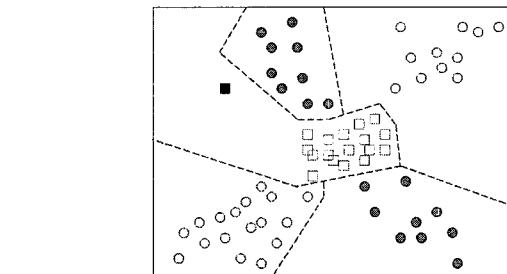


그림 1. 방사기저함수네트워크

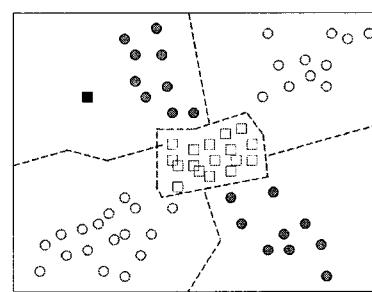
Fig. 1. Radial Basis Function Network

$$R_i(x) = \exp\left(-\frac{1}{2} \frac{\|x - c_i\|^2}{\sigma^2}\right) \quad (15)$$

이 경우 선형 분리가 아닌 클러스터 분리이므로 다양한 패턴이 모여 있는 패턴의 분류에 좋은 성능을 보인다. 이를 그림 2에서 (a)는 다중 퍼셉트론에 의한 분류로써 검은 사각 테스트 데이터가 들어왔을 때 선형 분리가 된 경우이며 (b)는 RBFN의 경우 클러스터 기반 분류로써 다른 형태로 분류한 것을 나타낸다. 그림 2에서 볼 수 있듯이 의 경우 선형 분류에서 발생할 수 있는 이러한 문제점을 개선할 수 있다.



(a) MLP의 분류
(a) Classification of MLP



(b) RBFN의 분류
(b) Classification of RBFN

그림 2. MLP와 RBFN의 비교
Fig. 2 Compare with MLP and RBFN

기본적인 RBFN의 학습방법은 입력데이터에 의한 출력과 실제 출력과의 오차를 이용한 역전파 알고리즘 (Backpropagation)을 통하여 방사기저함수의 파라미터를 최적화한다[6].

3. 시뮬레이션 및 결과

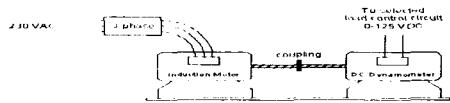
본 논문에서는 그림 3과 같이 전원부에서 전동기로 흐르는 전류를 측정하였다. 그림 4에서 전체 개념도를 나타내었다. 측정된 전류는 다시 주기별로 주성분 분석 기법을 이용하여 입력차원을 축소한 후 이를 통하여 패턴을 학습한다. 네트워크의 성능과 학습속도를 개선하기 위하여 네트워크의 초기 파라미터를 조건부 FCM을 이용하여 최적화한다.

실제 데이터의 구성은 6개의 패턴으로 되어 있으며 이를 주성분분석 기법으로 입력차원 축소 및 주성분 벡터를 변이 (고유치)의 크기순으로 4개로 정하였다. 또한 이를 이용하여 RBFN의 은닉층 노드의 수를 12개로 하였으며 조건부 FCM을 이용하여 초기 RBFN 파라미터의 중심 c_i 를 추정하였으며 Yager의 방법을 응용하여 분산 σ_i 를 데이터 공간에 대하여

여 균등하게 정하였다.



(a) 실험 구성도
(a) Experimental organization



(b) 실험 구조
(b) Experimental structure

그림 3. 실험 장치
Fig. 3 Experimental equipment

제안된 방법의 모델 생성 과정은 그림 4와 같다.

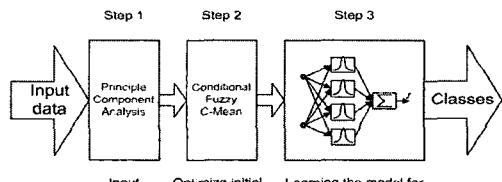


그림 4. 모델 생성 과정
Fig. 4 Process of generating modeling

학습데이터는 주성분 분석을 통하여 총 45개의 입력 차원을 가지는 54쌍을 생성하였으며 각 데이터의 공분산 행렬의 고유치가 큰 순서로 4개의 입력을 RBFN의 입력으로 선택하였고, 은닉층의 수를 12개로 하였다. 입력의 차원이 4차원이 되므로 입력 차원의 증가에 따른 RBFN의 노드 수 등의 증가문제를 해결할 수 있다[8][9]. 학습 전 먼저 조건부 FCM을 이용하여 초기 RBFN의 중심을 결정하였고 분산은 Yager의 방법을 응용하여 정하였다[10]. 학습은 총 50000번을 실시하였으며 생성된 모델에 대하여 각각 잡음이 포함된 경우를 포함하여 검증을 실시하였다. 모델의 학습은 잡음이 포함되어 있지 않은 데이터에 대하여 실시하였으며 학습된 모델에 대하여 신호대 잡음비(SNR)를 증가시키면서 각각의 인식률에 따른 성능을 비교하였다. 표 1에서 PCA를 이용한 고장진단 성능과 제안된 모델의 성능을 비교하여 나타내었다.

표 1. 성능지표(인식률)
Table. 1 Performance Index

| | PCA | PCA + RBFN |
|----------|----------|------------|
| Training | 100[%] | 100[%] |
| Checking | 100[%] | 100[%] |
| SNR40 | 92.56[%] | 98.14[%] |
| SNR30 | 92.56[%] | 98.4[%] |
| SNR20 | 90.74[%] | 96.29[%] |
| SNR10 | 88.89[%] | 90.74[%] |
| SNR15 | 72.22[%] | 77.77[%] |
| SNR5 | 40.74[%] | 59.25[%] |

표에서 볼 수 있듯이 제안된 방법에 의한 모델이 학습뿐만 아니라 잡음이 포함된 경우에도 우수한 성능을 보임을 알 수 있다.

4. 결론 및 향후 연구과제

본 논문에서는 유도전동기의 기계적 고장 검출을 위하여 이를 이용하였다. 유도전동기에서 검출된 신호를 주성분분석 방법을 이용하여 특징추출 및 입력 차원 축소를 실시하여 학습데이터의 입력 차원을 축소하여 RBFN의 은닉층 노드 증가문제를 해결하였으며 수렴속도 및 학습시간 개선을 위하여 초기 파라미터를 조건부 FCM을 이용하여 최적화하였다. 이와 같이 단계별 구조화와 최적화를 거친 모델의 고장진단 성능은 잡음을 포함한 유도전동기의 고장진단 성능에 대하여 우수한 성능을 나타내었다. 이는 주성분 분석의 선형 변환에 의한 특성에서 발생하는 잡음 증가시 성능 저하문제를 RBFN을 이용하여 계층적으로 개선함으로써 해결하는 것을 알 수 있다.

향후 연구과제로는 모델의 구조 간략화와 학습시간 및 성능 개선이 있으며 추후로 기계적 고장 검출뿐만 아니라 전기적 고장 검출까지 확장하여 하나의 모델로 일반적으로 발생할 수 있는 유도전동기의 모든 고장 상태를 진단하는 것이다.

참 고 문 헌

- [1] Chee-Mun Ong, "Dyanmic Simulation of Electric Machinery : Using Matlab/ Simulink", Prentice Hall, 1998.
- [2] Thomson, W.T., Fenger, M., "Current signature analysis to detect induction motor faults", IEEE Industry Applications Magazine, Vol. 7, Issue 4, pp. 26 -34, 2001.
- [3] Simon Haykin, "Neural Networks : A Comprehensive Foundation Second Edition", Prentice Hall, 1999.
- [4] Witold Pedrycz. "Conditional Fuzzy C-Means", Pattern Recognition, Letter 17, pp.625-631, 1996.
- [5] Witold Pedrycz, "Conditional Fuzzy Clustering in

- the design of Radial Basis Function Neural Networks", IEEE Trans on Neural Networks, Vol. 9, No. 4, pp. 601-612, 1998.
- [6] 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.
- [7] Chin-Teng Lin, C. S. George Lee, "Neural Fuzzy Systems : A Neuro-Fuzzy Synergism to Intelligent Systems", Prentice Hall, 1996.
- [8] J. S. R. Jang, "Input Selection for ANFIS Learning", Proceedings of the Fifth IEEE International Conference on, Fuzzy Systems, Vol. 2, pp. 1493-1499, 1996.
- [9] 김승석, 곽근창, 유정웅, 전명근, "계층적 클러스터링과 Gaussian Mixture Model을 이용한 뉴로-퍼지 모델링", 퍼지 및 지능시스템학회논문지, Vol. 13, No. 5, pp. 512-519, 2003.
- [10] R.R. Yager, D. P. Filev, "Generation of Fuzzy Rules by Mountain Clustering", Journal of Intelligence and Fuzzy System, Vol. 12, pp.209-230, 1994.



박장환(Jang Hwan Park)

1991년 : 충북대학교 전기공학과 (학사)
1993년 : 충북대학교 전기공학과(공학석사)
1999년 : 충북대학교 전기공학과(공학박사)
현재 : 충주대학교 정보제어공학과 계약 교수(BK21)

관심분야 : 강인제어, 음성인식 및 확률계통 해석



유정웅(Jeong-Woong Ryu)

1965. 2 : 한양대학교 전기공학과(공학사)
1976. 2 : 단국대학교 전자공학과(공학석사)
1987. 2 : 단국대학교 전자공학과(공학박사)
1979. 3-현재 충북대학교 전기공학과 교수

관심분야 : 가변구조제어, 지능제어, QFT
E-mail : jwryu@vod.chungbuk.ac.kr



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 전기전자 컴퓨터공학부 교수

관심분야 : Biometrics, 감정인식, 지능시스템



김승석(Sung-Suk Kim)

1998. 2 : 충주대학교 전기공학과(공학사)
2002. 2 : 충북대학교 전기공학과(공학석사)
2002. 3~현재 : 충북대학교 전기공학과
박사과정

관심분야 : 퍼지시스템, 신경회로망,
지능제어

E-mail : powerkim@chungbuk.ac.kr



이대종(Dae Jong Lee)

1995년 : 충북대학교 전기공학과(학사)
1997년 : 충북대학교 전기공학과(공학석사)
2002년 : 충북대학교 전기공학과(공학박사)
2003년~현재 : 충북대학교 컴퓨터정보통신연구소

관심분야 : 음성신호처리, 서명인식,
다중생체인식