

조건부 FCM과 방사기저함수네트웍을 이용한 유도전동기 고장 검출

Detection and Disgnosis of induction motor using Conditional FCM and Radial Basis Function Network

김승석, 김형배, 유정웅, 전명근
충북대학교 전기전자컴퓨터공학부

Sung-Suk Kim, Hyung-Bae Kim, Myung-Geun Chun, Jeong-Woong Ryu
Dept. of Electrical and Electronic Engineering
Chungbuk National University
E-mail : powerkim@vod.chungbuk.ac.kr

요 약

본 논문에서는 유도전동기 고장진단을 위하여 계층적인 하이브리드 뉴럴네트웍을 제안하였다. 시스템의 입출력 데이터에 근거하여 패턴을 분류하고자 할 때 직접적인 분류가 어렵거나 성능이 좋지 않을 경우 적절한 방법을 통하여 변환을 하거나 또는 패턴 분류기의 특성에 맞도록 변환하여 패턴 분류 성능을 향상하는 등 단계별 변환 및 분류 기법을 이용하였다. 제안된 방법에서는 실험에 의해 측정된 전류값을 주기별로 주성분분석(PCA) 기법을 이용하여 입력차원을 축소한 후 이를 조건부 FCM으로 방사기저함수의 초기치를 최적화하여 학습을 하였다. 이는 주성분분석이 가지는 특성을 이용하여 데이터의 특징을 나누었으며 이를 뉴럴네트웍의 학습 기능을 이용하여 모델의 최종 성능을 개선하는 것이다. 각각의 알고리즘이 가지는 특징을 활용하면서도 단점을 계층적으로 보완하여 유도 전동기 고장 진단 성능을 개선하였다. 이를 실제 계측된 유도전동기 데이터를 이용하여 제안된 방법의 유용성을 보이고자 한다.

1. 서론

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 고장원인으로는 크게 기계적 결함과 전기적 결함으로 크게 나누어진다. 결함 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 절연상태 검출을 제외한 대부분의 상태를 검출할 수 있으므로 현재 널리 사

용되고 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 획득한후 적절한 전처리 과정을 실시하고 이를 주성분분석(Principle Component Analysis :PCA)를 이용하여 입력 차원을 축소한다[3]. 이 입출력 데이터를 조건부 FCM(Conditional Fuzzy C-Mean)을 이용하여 초기 클러스터를 추정한후 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 조건부 Fuzzy C-Mean을 이용한 클러스터링 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 다층 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.

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

i 번째 중심(평균)에서의 j 번째 데이터와의 소속도를 중심과 데이터간의 거리 d 와 퍼지수 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.

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

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.

각중심과 데이터 간의 소속도 U 를 [0,1] 사이에서 식(3)의 조건에 만족하도록 임의로 설정한다.

$$\sum_{i=1}^c u_{ij} = f_{ij}(y_j), \quad \forall j=1, \dots, n \quad (3)$$

[단계 2] 퍼지 클러스터 중심 c_i 를 다음과 같이 계산한다.

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (4)$$

[단계 3] 다음과 같이 목적함수를 계산한후 종결 조건을 만족하면 알고리즘을 끝내고 그렇지 않으면 단계 4로 간다.

$$J(U, c_1, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_j u_{ij}^m d_{ij}^2 \quad (5)$$

[단계 4] 분할행렬 u_{ij} 를 식(2)와 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.

2.2 RBFN를 이용한 모델 최적화

뉴럴네트워크의 기본적인 형태인 다층 퍼셉트론과 유사한 RBFN는 그림 1과 같이 구성되어 있으며 식(6)과 같이 표현할 수 있다[6][7].

$$f(x) = \sum_{i=1}^c R_i(x) w_i \quad (6)$$

다층 퍼셉트론의 경우 활성화함수가 비선형의 선형 매핑을 위한 선형함수로 되어있는 반면 RBFN는 패턴의 클러스터 분류가 기본 형태이다. 즉 일반적인 RBFN는 식(7)와 같은 Gaussian 활성화함수를 사용한다.

$$R_i(x) = \exp\left(-\frac{1}{2} \frac{\|x - c_i\|^2}{\sigma^2}\right) \quad (7)$$

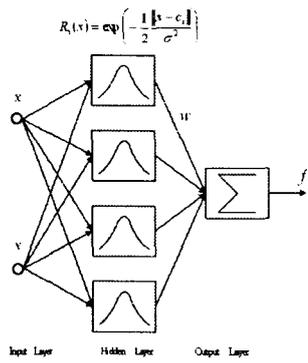
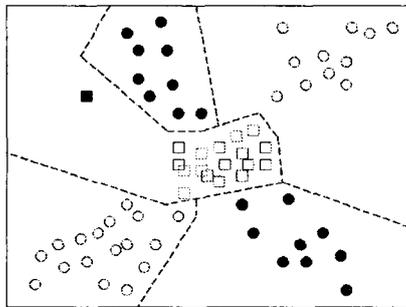
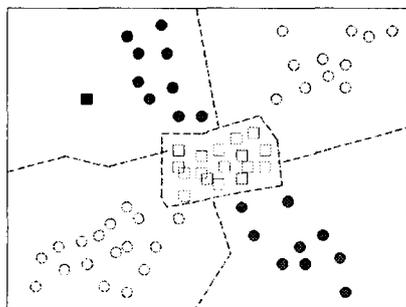


그림 1. 방사기저함수

이 경우 선형 분리가 아닌 클러스터 분리이므로 다양한 패턴이 모여 있는 패턴 분류에 좋은 성능을 보인다. 이를 표현하면 그림 2에서 (a)는 다층 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 RBFN의 경우 선형 분류에서 발생할 수 있는 이러한 문제점을 개선할 수 있다. 기본적인 RBFN의 학습방법은 입력데이터에 의한 출력과 실제 출력과의 오차를 이용한 역전파 알고리즘(Backpropagation)을 통하여 방사기저함수의 파라미터를 최적화한다[6].



(a) MLP의 분류



(b) RBFN의 분류

그림 2. MLP와 RBFN의 비교

3. 시뮬레이션 및 결과

본 논문에서는 그림 3과 같이 전원부에서 전동

기로 흐르는 전류를 측정하였다. 그림 4에서 전체 개념도를 나타내었다. 측정된 전류는 다시 주성분 분석 기법을 이용하여 입력차원을 축소한 후 RBFN을 통하여 패턴을 학습한다 [2][3][11]. 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 균등하게 설정하였다[10].



그림 3. 실험 장치

제안된 방법의 모델 생성 과정은 그림 4와 같다.

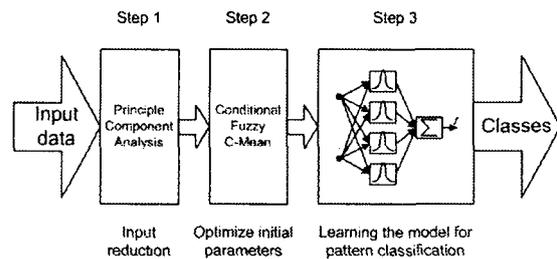


그림 4. 모델 생성 과정

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 중

심을 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. 그림 5와 표 1에서 PCA를 이용한 고장진단 성능과 제안된 모델의 성능을 비교하여 나타내었다. 표 1에서 볼 수 있듯이 제안된 방법에 의한 모델이 학습뿐만 아니라 잡음이 포함된 경우에도 우수한 성능을 보임을 알 수 있다.

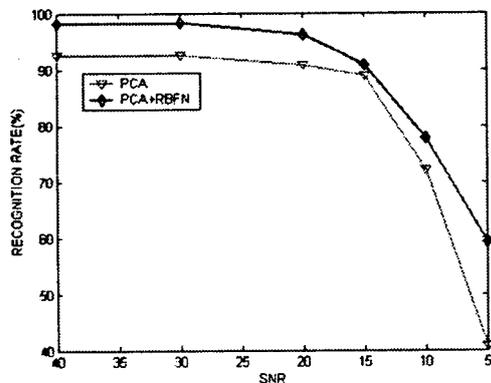


그림 5. 인식률

표 1. 성능지표(인식률)

	PCA	PCA + RBFN
SNR : 40	92.56[%]	98.14[%]
SNR : 30	92.56[%]	98.4[%]
SNR : 20	90.74[%]	96.29[%]
SNR : 10	88.89[%]	90.74[%]
SNR : 15	72.22[%]	77.77[%]
SNR : 5	40.74[%]	59.25[%]

4. 결론 및 향후 연구과제

본 논문에서는 유도전동기의 기계적 고장 검출을 위하여 RBFN을 이용하였다. 유도전동기에서 검출된 신호를 주성분분석 방법을 이용하여 특징추출 및 입력 차원 축소를 실시하여 학습데이터의 입력 차원을 축소하였다. 이러한 입력 차원의 축소는 RBFN의 은닉층 노드 증가문제를 해결하였고 또한 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 학습 시간 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.

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

6. 참고문헌

- [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 ANFS Learning", Proceedings of the Fifth IEEE International Conference on, Fuzzy Systems, Vol. 2, pp. 1493-1499, 1996.
- [9] 김승석, 광근창, 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.
- [11] Rechard O. Duda, Peter E. Hart, David G. Stork, "Pattern Classification", Wiley-Interscience, 2001.