

PCA와 비선형분류기에 기반을 둔 유도전동기의 고장진단

Fault Diagnosis of Induction Motor based on PCA and Nonlinear Classifier

이대종*, 박장환** 전명근*

*충북대학교 전기전자컴퓨터공학부

**충주대학교 정보제어공학과

Dae-Jong LEE, Jang-Hwan Park, Myung-Geun Chun

* School of Electrical and Computer Engineering Chungbuk National University

** Dept. of Information & Control Engineering Chungju National University

E-mail : mgchun@chungbuk.ac.kr

요 약

본 논문에서는 본 논문에서는, 주성분분석기법과 다층신경망에 기반을 둔 유도전동기의 고장진단기법을 제안하고자 한다. 입력의 수가 많을 경우 다층신경망만을 이용하여 분류하는 데는 한계가 있다. 이러한 문제점을 해결하기 위해 주성분분석기법에 의해 입력특징의 수를 축약한 후, 비선형분류기인 다층신경망을 적용하였다. 또한, 주성분 분석기법에 추출된 특징벡터가 고장상태별로 비선형성특성을 보일 경우 기존의 거리척도 기반에 의한 분류방법으로는 정확한 진단을 하는데 어려움이 있다. 이를 위해 비선형 분류기인 MLP를 적용함으로써 효과적인 고장진단을 하고자 한다. 제안된 기법은 다양한 실험을 통해 기존의 선형분류기에 비해 우수한 결과를 보임을 나타내고자 한다.

1. 서론

산업발달과 더불어 산업현장에서 전동기의 수요는 매년 증가하고 있다. 그 중에서도 유도전동기는 구조적으로 간단하고 견고할 뿐만 아니라 비용면에서도 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 기존의 연구들에서는 유도전동기의 진동신호를 처리하여 진단시스템을 구성하는 기계적 방법에 크게

의존해왔다. 진동신호를 고장진단을 위한 정보로 활용하는 경우에 대한 선행 연구가 많이 이루어져 있지만, 진동신호검출을 위해 부착하는 센서의 위치선정 등 진단을 위한 처리기법 이외에도 부가적인 데이터 취득 장치에 의해서 성능이 결정될 수 있다. 이러한 진동감지기법의 문제점으로 인하여 최근에는 전동기의 전류신호를 분석하는 MCSA (motor current signature analysis) 검출기법에 관한 연구가 활발히 진행되고 있다. MCSA 검출방법을 이용할 경우 절연상태를 제외한 고정자 및 회전자의 정적동적편심 및 배어링의 고장상태를 진단할 수 있다. 또한 온라인 상태에서도 고장진단을 수행할 수 있으므로 현재 널리 사용되고 있는 검출기법이다.[1-4]

MCSA 검출방법에 의해 전류신호를 취득한 후 진단을 위해 사용되는 유도전동기의 고장상태를 효과적으로 표현할 수 있는 특징추출 기법이

요구된다. 패턴분류 문제에 있어서 주성분분석기법(PCA: principal component analysis)이 사용된다[5,6]. 그러나, 주성분분석기법은 모든 입력차원의 선형성에 기반을 두고 있기 때문에 선형 특성에 대해서는 우수한 결과를 나타내나 비선형특성을 갖는 데이터에 대해서는 최적의 변환행렬을 구할 수 없는 문제점을 지니고 있다.

본 논문에서는 비선형 분류기로 널리 사용되고 있는 다층신경망(MLP:Multi-layer Perceptron)을 유도전동기 진단을 위한 분류기로 적용하고자 한다. 기존의 신경망은 차원의 저주 특성으로 인하여 입력차원이 높은 패턴에는 사용하는데 문제점이 있다[7]. 이러한 문제를 해결하기 위해 주성분분석기법에 의해 차원을 축소한 후 비선형 분류기를 적용하였다. 즉, 주성분분석기법에 의해 추출된 특징벡터가 고장상태별로 비선형성을 갖는다 하더라도 비선형 분류기를 적용함으로써 기존 문제점을 해결하였다.

본 논문의 구성은 다음과 같다. 2장에서는 제안된 유도전동기의 고장진단 시스템에 대하여 서술하고, 3장에서는 실험결과에 대하여 서술하였고 4장에서는 결론을 맺는다.

2. PCA와 LDA에 기반을 둔 제안된 고장진단 시스템

본 논문에서 제안된 유도전동기의 고장진단 시스템은 그림 1에서 보는 바와 같이 동기화 과정을 수행하는 전처리부, PCA기법에 기반을 둔 특징추출부, MLP에 기반을 둔 인식부로 구성되어 있다.

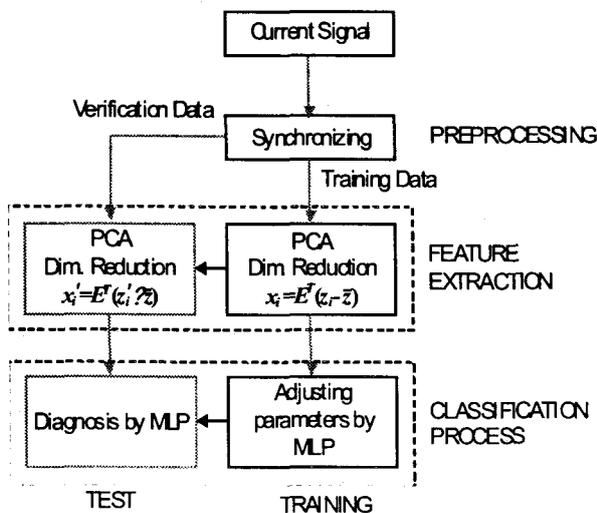


그림 1. 제안된 진단시스템의 구성도

동기화에서는 측정된 전류의 위상이 다를 경우 같은 고장의 데이터들이 다른 결과를 나타내기 때문에 측정된 전류신호의 원점을 0에 가깝게 조정한다. 즉, 원점을 기준으로 동기화 시킨 후 PCA기법에 의해 입력전류에 대한 특징벡터를 각각 산출한다.

PCA기법에 의한 특징추출 및 비교부에서는 훈련과정에서 미리 계산된 진단 모델별 특징벡터와 입력벡터간의 유클리드 거리를 산출한다. 여기서, 유도전동기의 운전상태는 건전상태, 베어링 고장, 회전자 휨, 회전자바 고장, 정적편심, 동적편심 등 6종류로 구성되어 있다. 최종 진단단계에서는 PCA기법에 의해 산출된 특징벡터를 MLP를 이용하여 분류하도록 하였다.

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.

$$\bar{X} = [\bar{x}_1, \bar{x}_2, \dots, \bar{x}_p], \quad \bar{\Omega} = \overline{XX^T} \quad (2)$$

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

$$\Omega_j = \lambda v_j \quad (3)$$

[단계 4] 고유벡터 v_j 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.

주성분분석기법은 모든 입력차원의 선형성에 기반을 두고 있기 때문에 선형 특성에 대해서는 우수한

결과를 나타내나 비선형특성을 갖는 데이터에 대해서는 기존의 Euclidean 기반 선형분류기에 의해서는 우수한 성능을 보이는데 한계가 있다. 따라서, 본 논문에서는 그림 2에서 보인 MLP 기반 비선형분류기를 이용하여 유도 전동기의 상태 진단을 하였다.

MLP사용되는 활성화함수로는 식(6)에 표현된 함수를 사용하였으며, 학습률은 다양한 실험에 의해 우수한 결과를 보이는 값들로 선택하였다.

$$f(x) = (1 - e^{-x})^{-1} \quad (6)$$

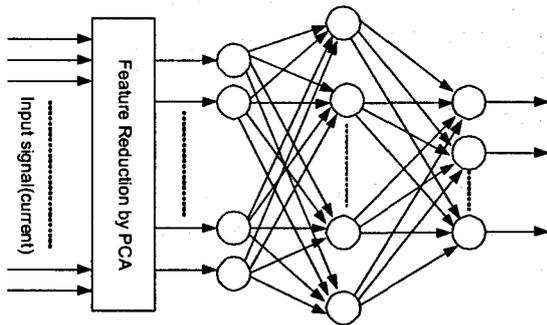


그림 2. MLP에 기반을 둔 비선형 분류기

최종 인식단계에서는 진단의 종류별로 설정된 출력값 중 가장 큰 값을 갖는 진단값을 선정하여 인식하였다. 즉, $\Omega = \omega_1, \omega_2, \dots, \omega_c$ 는 c 개의 클래스 라벨의 집합이라 하고, $D_i = [d_1(O_i), d_2(O_i), \dots, d_c(O_i)]$ 는 c 차원 벡터를 갖는 분류기 출력이라 하자. MLP에 의해 각 클래스에 대한 훈련데이터와 입력된 검증데이터 사이의 가장 우수한 유사도를 계산할 수 있다. 마지막으로, 분류는 식 (7)에 의해서 클래스들 사이의 가장 우수한 유사도를 갖는 클래스를 선택함으로써 얻어진다.

$$i_0 = \arg \max_i \{O_i\}, i=1,2,\dots,c \quad (7)$$

3. 실험 결과

제안된 기법의 유용성을 보이기 위해 유도 전동기의 고장상태별로 데이터를 취득하였다 [15]. 데이터 취득을 위한 시험장치는 3상 전원공급기, 시험할 전동기 및 부하장치(dynamometer)로 구성되어 있으며, 부하제어회로는 전력절환장치와 다른 부하 패턴을 공급하기 위한 제어장치로 구성하였다. 고장상태는 기본적으로 정상적인 상태, 회전자의 봉의 파손 상태, 회전자 축이 휘어진 상태, 정적편심 상태 및 동적편심 상태 등 6가지의 유도전동기의 운전상태를 진단한다. 사용된 데이터의 샘플링 개수는 1주기당 128개이며 전체

주기는 128회이다. 이 중에서 재 샘플링을 통해 유도전동기의 운전조건 당 18개의 사이클을 이용하였다. 최대 샘플링 주파수는 3kHz이고 샘플링 타임은 2.1333/16.384[sec] 이다. 고장모델을 형성하기 위해 사용된 학습 데이터는 총 데이터 108개[(18개/운전조건당)×6조건] 중 54개[(9개/운전조건당)×6조건]를 사용하였고, 모델의 검증을 위해 사용된 시험 데이터는 나머지 54개를 이용하였다. 또한 데이터를 랜덤하게 구성하여 10회 반복실험 하였다.

그림 3에서는 랜덤하게 선택된 데이터를 이용하여 반복 실험한 결과를 보이고 있다. 그림 *의 결과는 PCA에 의해 특징을 추출한 후 훈련벡터와 검증벡터간의 유사도 산출을 위해 Euclidean, Hamming 및 Mahalanobis 거리척도기반 선형분류기를 사용한 경우와 비선형 분류기인 MLP를 각각 적용하여 실험하였다. 그림 *에서 보는 바와 같이 MLP기반 비선형 분류기가 거리척도 기반 선형분류기에 비해 우수한 결과를 보이고 있다. 여기서, MLP의 은닉층 뉴런의 수는 20으로, 학습률은 0.005로 각각 설정하였다. 또한 PCA에 의한 산출된 특징벡터의 수는 다양한 실험을 통해 우수한 성능을 보일 때의 개수는 20으로 선정하였다.

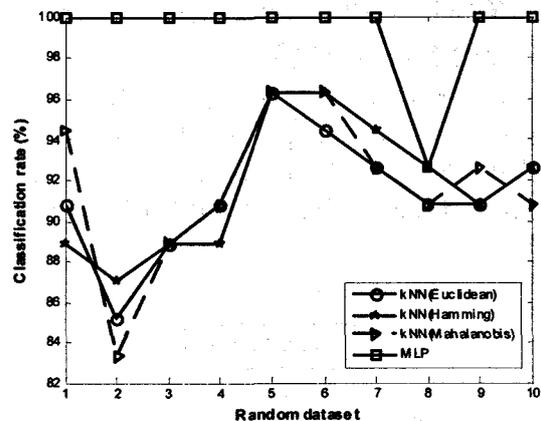


그림 3. 반복횟수에 따른 인식률

그림 4에서 보는 바와 같이 10회의 반복실험에 대한 평균치를 분류기 분류기법별로 구분하여 나타냈다. 그림 4에서와 같이 MLP기반 비선형 분류기를 적용한 결과 진단율이 99.3%로 보여 기존의 거리척도 기반 선형분류기에 비해 최대 6% 향상된 결과를 나타냈다. 표 1에서는 고장상태별 인식결과를 보이고 있다. 이 표에서 보는 바와 같이 기존의 거리척도 방법으로는 회전자 휨, 회전자 바, 정상편심에 대해 인식률이 저조하였으나, MLP기반 비선형 분류기에 의해서는 고장상태별 인식이 효과적임을 알 수 있다.

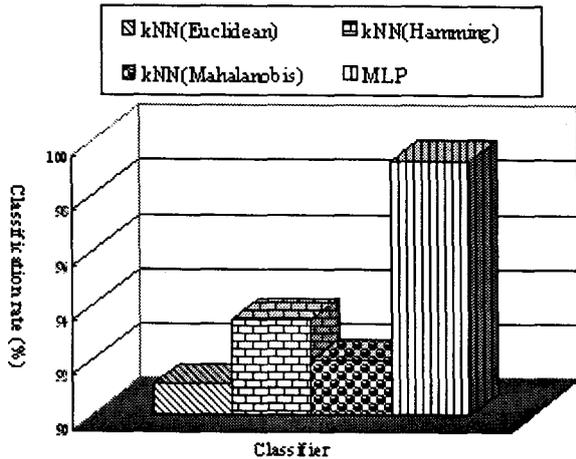


그림 4. 분류기에 따른 평균 인식률

표 1. 고장상태별 인식결과

Faulty Condition	k-NN (k=1)			MLP
	Euclidean	Hamming	Maha	
Healthy mode	97.8	98.9	97.8	100
Bearing	98.9	95.6	100	100
Bowed rotor	80.6	83.3	74.4	97.8
Rotor bar	85.6	93.3	90.0	100
Static eccen.	87.8	90.0	90.0	97.8
Dynamic eccen.	97.8	100	100	100

4. 결론 및 향후과제

본 논문에서는 PCA와 MLP에 기반을 둔 유도 전동기 고장진단 기법을 제안하였다. PCA에 의해 특징벡터를 산출한 후 비선형 분류기인 MLP를 적용함으로써 고장상태별로 효과적으로 분류하도록 하였다. 실험결과 기존의 거리척도 방법으로는 회전자 힘, 회전자 바, 정상편심에 대해 인식률이 저조하였으나, MLP기반 비선형 분류기에 의해서는 고장상태별 인식이 효과적임을 알 수 있다. 또한 반복실험에 의한 인식결과의 평균값을 기준으로 하여, MLP기반 비선형 분류기를 적용한 결과 진단율이 99.3%로 나타났으며, 이는 기존의 거리척도 기반 선형분류기에 비해 최대 6% 향상된 결과를 나타냈다.

5. 참고문헌

- [1] Nejari, H., Benbouzid, M.E.H., "Monitoring and diagnosis of induction motors electrical faults using a current Park's vector pattern learning approach", IEEE Transactions on Industry Applications, Vol. 36, Issue 3, pp. 730-735, 2000.
- [2] Bellini, A., Filippetti, F., Franceschini, G., Tassoni, C., Kliman, G.B., "Quantitative evaluation of induction motorbroken bars by means of electrical signature analysis", IEEE Transactions on Industry Applications, Vol. 37, Issue 5, pp. 1248-1255, 2001.
- [3] Kyusung Kim, Parlos, A.G., Mohan Bharadwaj, R., sensorless fault diagnosis of induction motors, IEEE Transactions on Industrial Electronics, Vol. 50 Issue 5, pp. 1038-1051, 2003.
- [4] Zidani, F., El Hachemi Benbouzid, M., Diallo, D., Nait-Said, M.S., "Induction motor stator faults diagnosis by a current concordia pattern-based fuzzy decision system", IEEE Transactions on Energy Conversion, Vol. 18, Issue 4, pp. 469-475, 2003.
- [5] M. Turk and A. Pentland, "Face recognition using eigenfaces", IEEE Conf. on Computer Vision and Pattern Recognition, pp. 586-591, 1991.
- [6] Wang, Y., Van Huffel, S., Vanhamme, L., Mastronardi, N., Van Hecke, P., "Advanced signal processing methods for quantitation of resonances in magnetic resonance spectra", Proc.,13th IEEE Symposium on Computer-Based Medical Systems, pp.63-68, 2000.
- [7] Wei-Zhen Lu, Wen-Jian Wang, Xie-Kang Wang, Sui-Hang Yan and Joseph C. Lam, "Potential assessment of a neural network model with PCA/RBF approach for forecasting pollutant trends in Mong Kok urban air, Hong Kong"Environmental Research, Vol. 96, Issue 1, pp.79-87, 2004.