

KPCA 특징추출기법을 이용한 유도전동기 결합 진단 연구

한상보, 황돈하, 강동식
한국전기연구원 전력설비진단연구그룹

Study on Faults Diagnosis of Induction Motor Using KPCA Feature Extraction Technique

Sang-Bo Han, Don-Ha Hwang, and Dong-Sik Kang
Korea Electrotechnology Research Institute(KERI), Power Facilities Diagnosis Research Group

Abstract – 본 연구는 유도전동기 진단시스템을 개발하기 위하여 테스트 전동기 내부에 취부된 자속센서 신호를 사용한 알고리즘 적용 결과를 논한 것으로서 분류기별 고장 판별 정확도에 대하여 서술하였다. 특징추출은 Kernel Principal Component Analysis (KPCA) 방법을 이용하였으며, 테스트 샘플들에 대해서는 LDA(Linear Discriminant Analysis)와 k-NN(k-Nearest neighbors) 분류기법을 이용하여 판별하였다. 회전자 바 손상이나 편심(동적/정적)인 경우는 두 가지 분류기 모두 95[%] 이상의 높은 분류 정확도를 보였지만, LDA인 경우 정상상태를 비롯한 베이링 불량이나, 소프트 변형인 경우는 낮은 분류율을 보였다.

1. 서 론

최근, 회전기 기류의 정상 및 고장 상태를 정확히 예지(prognosis) 및 진단(diagnosis)하기 위하여 전류, 전압, 온도, 회전속도, 진동 등과 같은 신호들을 이용한 많은 측정 방법들이 개발되어 실제 산업현장에서 적용되고 있다. 특히 이러한 신호들 중에서 전동신호를 측정한 진단시스템이 널리 이용되고 있으며, 고장여부에 대한 판단 기준도 이미 발표되어 있다.[1]-[4] 그러나, 이러한 전동신호에 의한 결합 추출도 결합종류에 따른 분류 한계가 있으므로, 전류나 토크 센서 등을 복합화하여 최적 시스템을 개발하기 위한 연구도 진행되고 있다. 또한, 고정자 전류성분의 전원주파수 부근 측대역 성분들을(sidebands) 측정하여 회전자 결합 유무를 진단하는 방법이 있지만, 측대역 성분들은 슬립에 의존하고 있어서 부하를 투입하여 회전자의 속도변화를 일으켜야만 하는 단점이 있다. 이러한 단점을 극복하기 위하여 기동시의 과도한 전류를 측정하여 이산웨이블렛 변환(Discrete Wavelet Transform)을 통한 과도시간 동안의 고조파 주요 성분들의 변화를 분석하여 회전자 결합을 진단하는 기법도 발표되었다.[5]

본 연구에서는 전동기의 주요한 고장 중에서 대표적 6가지 결합을內포한 모의 전동기를 제작하여, 부하를 투입한 정상상태 조건에서 전동기 내부에 취부된 자속센서에 의한 공극의 유기기전력을 측정하고, 취득된 데이터들을 자체 개발한 알고리즘에 적용하여 고장 판별 정확도에 대하여 논하였다.

2. 알고리즘 및 측정 시스템

2.1 알고리즘의 개요

알고리즘은 훈련 및 테스트 두 단계로 나누어지며, 훈련과정은 취득된 신호로부터 여러가지 원하는 특징들을 계산하고 계산된 특징을 정규화시킨 후, KPCA(Kernel Principal Components Analysis)에 의해 3차원 공간으로 투영하여 클러스터 군을 형성시키도록 되어 있다. 테스트 과정은 테스트에 적용할 신호들을 훈련과정과 동일하게 특징 계산 및 정규화 과정을 거쳐서 KPCA법에 의하여 3차원 공간으로 투영하게 되고, 이렇게 투영된 데이터들을 각 클러스터 군들과의 거리를 계산하여 가장 근접한 클러스터 군을 선택하도록 되어 있다. 마지막 단계의 최종 판단 방법에는 LDA(Linear Discriminant Analysis)와 k-NN(k-Nearest neighbors) 분류기법을 적용하였다.

2.1.1 KPCA 특징추출기법

비선형 접근방법인 Kernel 함수를 이용한 선형 PCA(Principal Component Analysis)를 사용하는 방법으로서, 입력벡터를 고차원 특징 공간으로 사상시키고 이렇게 사상된 벡터들을 PCA에 의해 선형적으로 계산하는 방법을 의미한다. 즉, 원래의 입력벡터와 최종적으로 계산된 벡터사이에는 비선형 관계가 있음을 나타낸다. 입력 벡터 x_j 를 고차원 $\psi(x_j)$ 특징 공간으로 사상시키고 $\psi(x_j)$ 에 대해 PCA를 실시하는 방법이다. $\psi(x_j)$ 의 선형 PCA는 x_j 에 대해 비선형 PCA의 관계가 있다. 식 (1)과 같이 고유치 문제를 계산함에 의하여 고유벡터들의 주요한 요소들을 3차원 공간으로 사상시키는 군을 형성시키게 된다.

$$\lambda_j u_j = \tilde{K} u_j, j=1, \dots, N \quad (\text{식 } 1)$$

여기서, $\tilde{K} = \frac{1}{N} \sum_{j=1}^N \psi(x_j) \psi(x_j)^T$ 는 $\psi(x_j)$ 의 상호 상관 행렬이며,

λ_j 는 0 이 아닌 고유치 값이다. u_j 는 고유벡터이다. 고유치들은 $\lambda \geq 0$ 와 $u \in F$ 의 조건을 만족해야 한다. 식 (1)로부터 얻어진 가장 큰 고유치 λ 에 따른 고유벡터 u 는 특정 공간 F 상에서 주요소(PC : Principal Component)가 되며, 가장 작은 고유치에 따른 고유벡터는 마지막 주요소가 된다. Kernel $K(x_i, x_j)$ 의 종류로는 Linear, Polynomial, Gaussian RBF가 있으며, 본 연구에서는 Gaussian RBF ($\gamma = 4$) 이용하였다.

단계 1 : 취득된 신호로부터 특징 계산 및 정규화시킨 후, 정규화된 특징값들 (x_i, x_j)을 커널 함수를 이용하여 식 2에 의해 $\psi(x)$ 를 계산한다.

$$\psi(x_i) \cdot \psi(x_j) \equiv K(x_i, x_j) \quad (\text{식 } 2)$$

단계 2 : 커널 함수로 계산된 데이터들을 고차원화 된 좌표공간 F상의 중심으로 옮긴다.

$$\psi(x) \equiv \psi(x) - \frac{1}{N} \sum_{i=1}^N \psi(x) \quad \forall X \in \mathbb{R}^n \quad (\text{식 } 3)$$

단계 3 : 식 4에 의해 행렬 \tilde{K} 의 고유치를 계산하고, 크기순으로 나열하여 고유치에 기초한 주성분들을 선택한다.

$$\begin{aligned} \tilde{K}_{ij} &\equiv \left\langle (\Phi(x_i) - \frac{1}{N} \sum_{k=1}^N \Phi(x_k)) \square (\Phi(x_j) - \frac{1}{N} \sum_{l=1}^N \Phi(x_l)) \right\rangle \\ &= \mathbf{K}_{ij} - \frac{1}{N} \sum_{k=1}^N E_{ik} \mathbf{K}_{kj} - \frac{1}{N} \sum_{l=1}^N E_{il} \mathbf{K}_{lj} + \frac{1}{N^2} \sum_{k,l=1}^N E_{ik} \mathbf{K}_{kl} E_{lj} \\ &= (\mathbf{K} - E_N \mathbf{K} - \mathbf{K} E_N + E_N \mathbf{K} E_N)_{ij}. \end{aligned} \quad (\text{식 } 4)$$

2.1.2 분류기의 특징

1) LDA(Linear Discriminant Analysis):

선형 변환 행렬을 이용하여 같은 특징을 갖는 클러스터 내부의 요소들의 분산을 최소로 하고, 군집과 군집간의 거리는 최대가 되도록 사영함으로서 군집 내부 및 군집과 군집간의 공분산 행렬을 이용하는 방법을 의미한다.

2) k-NN(k-nearest neighbor algorithm):

특징공간에 있어서 훈련 샘플들에 가장 근접한 테스트 샘플을 분류하기 위한 패턴 인식법이다. 훈련 샘플들은 다차원 특징 공간에 구성되며 클래스에 의해서 여러 영역으로 분류된다. 이러한 다차원 공간상의 새로운 테스트 샘플은 훈련 샘플들과 k번쨰 이내로 가장 근접한 클래스에 소속시키게 된다. 본 연구에서는 $k = 3$ 으로 설정하였다.

2.1.3 특징 계산

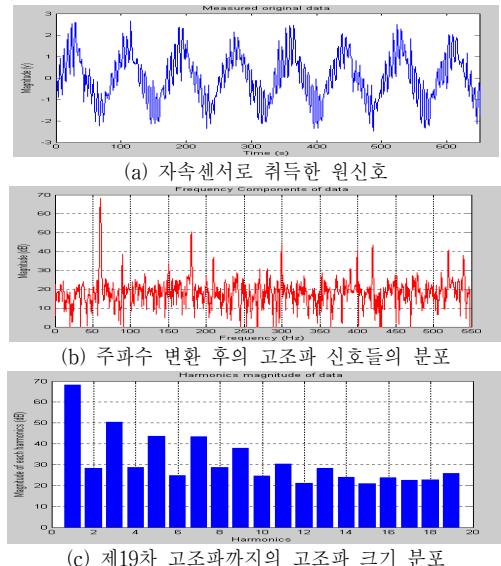
센서 신호의 시계열 데이터를 주파수 변환(Fast Fourier Transform, FFT)하여 전원주파수를 포함한 제19차 고조파까지 피크 값들의 특징 분포를 그림 1(d)와 같이 조사하였다. 이때 측정 신호의 데이터 수(측정시간) 및 샘플링 율에 따라서 주파수 변환에 따른 결과가 발산되는 오류를 방지하기 위해서 hanning 윈도우를 적용한 후 변환하였다. 그림 2는 자속센서를 사용한 시계열 신호에서 고조파 성분들의 크기를 추출한 후, 그 특징분포 중 고장 결합들을 잘 구별할 수 있는 고조파 특징들의 일부를 나타낸 것이다. 자속 센서에 적절한 고조파 성분들을 선택하여 알고리즘에 적용하였다. 제2차 고조파인 경우는 회전자 손상인 경우를 제외하고 거의 유사한 특징분포를 보이고 있으며, 제3고조파는 질량 불평형인 경우가 다른 결합에 비해 큰 분포를 보였다. 아울러 제5고조파인 경우는 고정자 결합인 경우 대체적으로 낮음을 알 수 있다.

2.2 측정 시스템

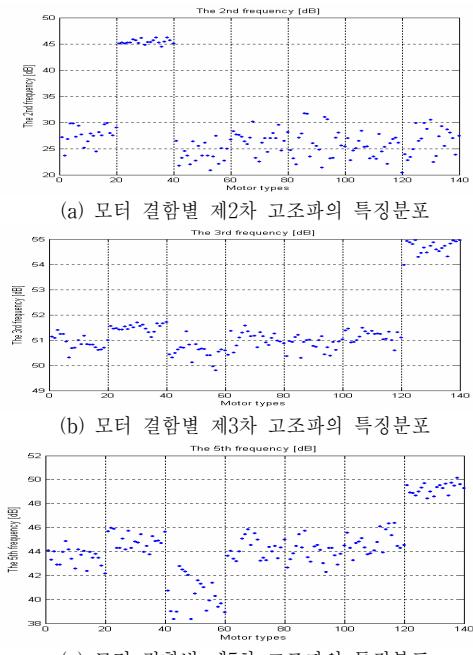
전동기의 주요한 고장은 소프트의 변형, 회전자의 정적편심 및 동적편심, 베어링 불량, 회전자 바 손상, 고정자 퀀션의 단락 등을 들 수 있다. 이러한 고장들을 모의하기 위하여 그림 3에 보인 것과 같이 정상 전동

기를 포함하여 총 7가지의 전동기를 모의 제작하였다. 그림에 보인 것처럼 테스트 전동기(A)와 부하 상태를 가변할 수 있는 부하 전동기(B)를 커플링으로 직결하여 부하상태에서 테스트를 진행하였다. 자속 센서는 자체적으로 개발하여 전동기 내부에 취부하여 각 모터별 20회씩 Synergy(DAQ, 샘플링율 및 측정시간 가변 가능)을 사용하여 측정하였다. 측정조건으로는 5[KS/s]로 1.64[s]동안 8,192samples을 측정하여 컴퓨터에 반복·저장하였다. 이때의 주파수 분석 최대주파수는 2.5[kHz]이며, 주파수 분해능은 0.61[Hz]이다. 측정된 20회 데이터 중에서 초기 10회 측정 데이터를 이용하여 특징추출(Feature extraction)을 실시했으며, 나머지 10회 데이터를 활용하여 고장을 모의한 모터에 따른 알고리즘의 정확한 판단여부를 분류기에 따라서 조사하였다.

그림 3의 우측은 자체 개발한 자속센서의 구조를 보인 것으로서 전동기 고정자 권선부의 웨지 상부에 설치하여 공극에서 발생한 자속을 용이하게 검출하도록 제작되었다.



<그림 1> 시계열 데이터의 주파수 변환 및 각 고조파 크기별 추출



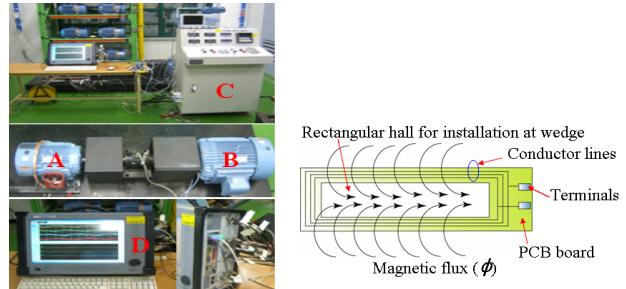
<그림 2> 모터 결함 종류에 따른 고조파 특징 분포

(1-20: Bearing fault, 21-40: Broken rotor bar, 41-60: Stator fault, 61-80: Normal motor, 81-100: Bowed rotor bar, 101-120: Misalignment, 121-140: Mass unbalance)

3. 분류기별 고장 판별 결과

표 1은 자속 센서를 이용한 유도전동기 결합별 분류율 결과를 보인 것으로서, 회전자 바 손상이나 편심(동적/정적) 고장은 두 가지 분류기 모두 95[%]이상의 높은 분류율을 보였지만, 정상상태를 비롯한 베이링 불량이나, 샤프트 변형인 경우는 LDA에 있어서 낮은 분류율을 보였다.

또한, k-NN인 경우가 LDA 분류기법에 비하여 우수한 결합 분류율을 보였으며, 모든 결합에 대하여 70[%] 이상의 분류율을 보였다. 이와 같이 동일한 분류기에 대해서도 각 결합별 분류결과가 크게 상이함을 알 수 있다. 이는 공극에서의 자속 분포가 결합 유형에 따라 큰 차이를 보이는 경우가 있는 반면, 그렇지 못한 경우에 따른 결과로 판단된다. 따라서 높은 분류율을 얻기 위해서는 각 결합 유형을 명확히 판별할 수 있는 최적의 특징 선택이 중요하다고 볼 수 있다.



<그림 3> 유도전동기 결합 측정 시스템 및 자속센서의 구조

<표 1> 자속센서 1개를 이용한 전동기 결합 유형에 따른 분류기별 판단 정확도

결합 종류	분류율 (%)	
	LDA	k-NN
베이링 불량	30	80
회전자 바 손상	100	100
고정자 권선의 단락	100	95
정상 상태	30	90
샤프트의 변형	75	70
동적편심	100	100
정적편심	95	95

4. 결론

본 논문은 유도전동기 진단 시스템을 개발하기 위하여 자체 개발한 자속 센서의 주파수 분석을 통하여 특징계산 후, 자체 알고리즘에 적용하여 전동기 고장 유형에 따른 분류기별 분류 정확도에 대하여 논하였으며, 다음과 같은 결론을 얻었다.

(1) 유도전동기의 고장 유형별 분류율을 조사하기 위하여 KPCA 특징 추출기법 및 LDA와 k-NN 분류기법을 적용한 알고리즘을 개발하였다.

(2) 회전자 바 손상이나 편심(동적/정적)인 경우는 두 가지 분류기 모두 95[%]이상의 높은 분류 정확도를 보였지만, LDA인 경우 정상상태를 비롯한 베이링 불량이나, 샤프트 변형인 경우는 낮은 분류율을 보였다. 그러나, k-NN인 경우가 LDA 분류기법에 비하여 우수한 결합 분류율을 보였으며, 모든 결합에 대하여 70[%] 이상의 분류율을 보았다.

(3) 동일한 분류기에 대해서도 각 결합별 분류결과가 크게 상이함을 알 수 있으며, 이는 센서에 따른 각 결합들을 판별할 수 있는 최적의 특징 선택이 매우 중요하다고 볼 수 있다.

[참고 문헌]

- W. T. Thomson, et al., "On-line Current Monitoring to Diagnosis Airgap Eccentricity in large Three-Phase Induction Motors-Industrial Case Histories Verify the predictions", IEEE Trans. on Energy Conversion, Vol. 14, No. 4, pp. 1372~1378, 1999.
- Olivier Ondel, Emmanuel Boutleux, and Guy Clerc, "A Method to Detect Broken Bars in Induction Machine Using Pattern Recognition Techniques", IEEE Trans. Indus. Appl., Vol. 42, No. 4, pp. 916~923, 2006.
- Humberto Henao, Member, IEEE, Cristian Demian, and Gérard-André Capolino, Fellow, IEEE, "A Frequency-Domain Detection of Stator Winding Faults in Induction Machines Using an External Flux Sensor", IEEE Trans. Indus. Appl., Vol. 39, No. 5, pp. 1272~1279, 2003.
- Sergio M. A. Cruz and A. J. Margues Cardoso, "Stator Winding Fault Diagnosis in Three-Phase Synchronous and Asynchronous Motors, by the Extended Park's Vector Approach", IEEE Trans. Indus. Appl., Vol. 37, No. 5, pp. 1227~1233, 2001.
- Jose A et al., "Validation of a New Method for the Diagnosis of Rotor Bar Failures via Wavelet Transform in Industrial Induction Machines", IEEE Trans. IAS, Vol. 42, No. 4, 2006.