

EM 알고리즘 기반 강인한 진동 특징을 이용한 고 신뢰성 유도 전동기 다중 결함 분류

High-Reliable Classification of Multiple Induction Motor Faults Using Vibration Signatures based on an EM Algorithm

장원철* · 강명수** · 최병근*** · 김종면†

Won-Chul Jang, Myeongsu Kang, Byeong-Keun Choi and Jong-Myon Kim

Key Words : Fault classification(고장 분류), LPC analysis(선형 예측 코딩 분석), EM algorithm(EM 알고리즘), Mahalanobis distance(마할라노비스 거리)

ABSTRACT

Industrial processes need to be monitored in real-time based on the input-output data observed during their operation. Abnormalities in an induction motor should be detected early in order to avoid costly breakdowns. To early identify induction motor faults, this paper effectively estimates spectral envelopes of each induction motor fault by utilizing a linear prediction coding (LPC) analysis technique and an expectation maximization (EM) algorithm. Moreover, this paper classifies induction motor faults into their corresponding categories by calculating Mahalanobis distance using the estimated spectral envelopes and finding the minimum distance. Experimental results shows that the proposed approach yields higher classification accuracies than the state-of-the-art approach for both noiseless and noisy environments for identifying the induction motor faults.

1. 서 론

유도 전동기는 팬, 송풍기, 펌프, 컨베이어 및 압축기 등 대부분의 산업현장에 사용되는 주요한 동력 공급원이다. 이러한 대전력 공급에 사용되는 유도 전동기의 결함은 생산 설비 성능 저하와 관련되어 막대한 경제적 손실과 모터의 수리 및 보수비용을 초래하기 때문에 결함을 사전에 방지하고 결함발생 시 손실을 최소화하기 위한 상태 모니터링(condition monitoring) 시스템에 대한 연구가 활발히 진행되고

있다^(1,2,3).

유도 전동기의 운전 상태를 점검하기 위해 진동 신호가 널리 이용되는데, 진동 신호에는 유도 전동기와 같은 회전 기계의 결함 유형별 고유의 특징들이 포함되어 있기 때문이다. 하지만 진동 신호에 포함된 결함 유형별 특징을 반영하는 파라미터는 대부분 숨겨져 있으므로 취득한 진동 신호를 결함 검출 및 분류 시스템에 직접적으로 이용하기에는 어려움이 있다. 따라서 취득한 진동 신호로부터 결함 유형별 특징을 잘 나타낼 수 있는 특징 벡터를 추출하는 방법은 유도 전동기 결함 검출 및 분류 시스템에 있어 매우 중요하다^(4,5,6).

최근 유도 전동기의 결함 유형별 분류를 위해서는 신호를 사전에 분석하고, 결함 유형별 특징을 효과적으로 추출하여 분류 알고리즘의 입력으로 사용함으로써 결함을 분류하는 형태로 연구가 활발히 진행되고 있다. 유도 전동기의 결함 상태를 효과적으

† 교신저자; 정회원, 울산대학교 전기공학부
E-mail : jmkim07@ulsan.ac.kr
Tel : (052)259-1637, Fax : (052)259-1687
* 울산대학교 전기전자컴퓨터공학과
** 정회원, 울산대학교 전기전자컴퓨터공학과
*** 정회원, 국립경상대학교 에너지기계공학과

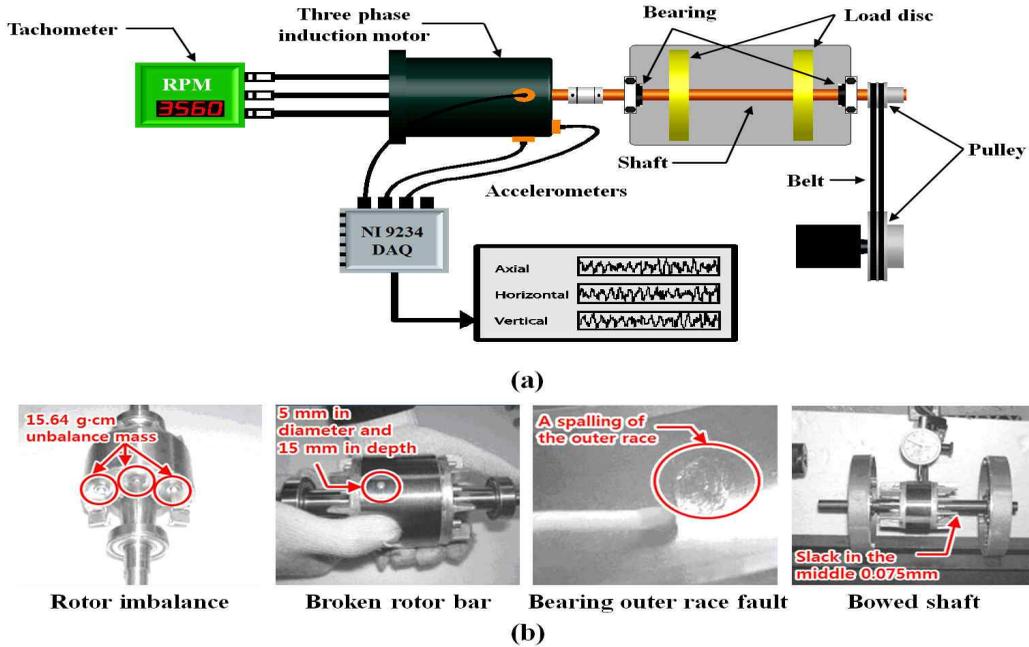


Fig. 1 Self-defined test rig for the experimental setup (a) and faulty induction motors (b)

로 표현할 수 있는 특징 추출 기법에는 고속 푸리에 변환(fast Fourier transform, FFT)을 이용하여 특징 주파수(characteristic frequency)를 추출하는 방법이 주로 사용되어 왔다. 하지만 주파수 스펙트럼의 경우 시간이 지나면서 유도 전동기 동작 상태가 변하거나 부하의 변동 등으로 인해 특징 주파수 성분의 변동이 발생하므로, 결함 유형별 정확한 특징 주파수를 추출하는데 어려움이 있다^(7,8,9). 따라서 본 논문에서는 특징 주파수의 미미한 변동으로 인해 야기되는 유도 전동기 결함 분류 성능 감소를 줄이기 위해 선형 예측 코딩(linear prediction coding, LPC) 분석 및 EM(expectation maximization) 알고리즘을 이용하여 특징 주파수 대역의 미미한 변동이 생기더라도 각 결함 유형별 특징을 잘 묘사할 수 있는 스펙트럼 포락선을 추정한다. 이렇게 추정된 스펙트럼 포락선을 이용하여 각 결함 유형별 강인한 참조 특징 벡터를 추출 이를 바탕으로 알려지지 않은 입력 신호에 대한 특징 벡터와의 마할라노비스 거리(Mahalanobis distance, MD)를 구함으로써 유도 전동기 다중 결함을 분류한다. 또한 본 논문에서는 제안하는 알고리즘의 성능 평가를 위해 2011년에 출판된 2차원 공간에서 진동 신호의 특징을 이용한

유도 전동기 다중 결함 분류 알고리즘과 분류 정확도 측면에서 그 성능을 검증한다⁽¹⁰⁾.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문에서 사용한 유도 전동기 결함 유형과 각 결함 유형별 진동 신호 취득 환경을 설명한다. 3장에서는 본 논문에서 제안하는 유도 전동기 다중 결함 분류 시스템을 소개하고, 4장에서는 제안한 알고리즘의 성능 및 기존 알고리즘과의 성능 비교 결과를 각각 보여준다. 마지막으로 5장에서 본 논문의 결론을 맺는다.

2. 유도 전동기 결함 유형

본 논문에서는 정상적으로 동작하는 유도 전동기를 포함 일곱 가지 유도 전동기 결함을 취득하기 위한 실험 환경은 Fig. 1(a)와 같으며, 실험에 사용한 유도 전동기는 0.5 kW, 220 V, 3650 RPM(revolutions-per-minute)로 동작한다. 일곱 가지 결함 유형의 진동 신호 취득을 위해 총 4개의 유도 전동기를 사용하였으며, 이 중 하나는 정상 상태의 전동기이다. 먼저 정상 상태의 유도 전동기를 이용하여 정상, 각 정렬 불량, 평형 정렬 불량 및 회전자

Table 1 Description of faults of the induction motor

Type of fault	Fault description
Angular misalignment fault (AMF)	Angular misalignment is the effective angle between the two shaft centerlines, where the angle between the shaft centerlines is 0.48° in this study
Broken rotor bar fault (BRBF)	12 of 34 rotor bars are involved in the plastic deformation of the grinding furrow as depicted in Fig. 2(b): 5 mm in diameter and 15 mm in depth
Normal (NO)	The induction motor is normal (or healthy)
Rotor unbalance fault (RUF)	Unbalanced mass of 15.64 g·cm is added at the right end of the rotor as shown in Fig. 2(b)
Bearing fault (BF)	A spalling on the outer race of the bearing is replicated as presented in Fig. 2(b)
Bowed shaft fault (BSF)	The shaft is slack in the middle (0.075 mm), which causes dynamic air-gap eccentricity
Parallel misalignment fault (PMF)	Parallel misalignment is the effective perpendicular distance between the two shaft centerlines, where the distance between the shaft centerlines is 15 mm in this study

불균형 신호를 취득하였고, 나머지 세 개의 유도 전동기를 통해서 회전자 봉 파손 결함, 굽어진 회전자 결함, 베어링 외륜 결함 신호를 각각 취득하였으며 그 결함은 Fig. 1(b)와 같다. 이와 같이 정상 및 일곱 가지 결함에 대해 8,000 Hz로 샘플링된 1초 길이의 진동 신호 105개를 축 방향, 수평 방향, 수직 방향으로 유도 전동기에 부착된 가속도 센서로부터 취득하였고, 신호 분석 결과 축 방향의 진동 신호에서 각 결함 유형별 특징을 잘 나타내었다. 따라서 본 논문에서는 축 방향 진동 신호를 유도 전동기 결함 분류에 사용하며, Table 1은 유도 전동기 결함 유형과 그에 대한 간단한 설명이다.

3. 유도 전동기 결함 분류 시스템

본 논문에서는 선형 예측 코딩(linear prediction coding, LPC) 분석 및 EM(expectation maximization) 알고리즘 등의 기법을 이용하여 부하 변동 또는 공급되는 입력 전원으로 인해 동일한 유도 전동기 결함일지라도 그 특징 주파수가 미미하게 변하는데서 기인하는 분류 성능의 저하를 최소화하고자 한다. 또한 유도 전동기 결함 분류를 위해 본 논문에서는 훈련 데이터(training data)로부터 LPC 분석 및 EM 알고리즘을 통해 유도 전동기 결함 유형별 참조 특징 벡터(reference feature vector)를 생

성하고, 참조 특징 벡터와 테스트 데이터(test data)로부터 추출한 특징 벡터 사이의 마할라노비스 거리(Mahalanobis distance, MD)를 구하고 그 거리가 최소가 되는 범주로 결함을 분류한다. 먼저 아래에서는 본 논문에서 제안하는 유도 전동기 결함 분류 시스템에서 사용되는 기법들을 소개한다.

3.1. 선형 예측 코딩(LPC) 분석

유도 전동기 결함 유형별 스펙트럼 포락선(spectrum envelope)을 나타내기 위해 본 논문에서는 LPC 분석 기법을 이용한다⁽¹¹⁾. LPC는 과거의 인접한 샘플들로부터 현재의 샘플을 예측하여 신호를 표현하는 방법으로 식(1)과 같이 표현된다.

$$\hat{x}[n] = \sum_{k=1}^p a_k x[n-k], \quad (1)$$

여기서 $a_k, k=1,2,3,\dots,p$ 는 LPC 계수이고, p 는 선형 예측 계수의 차수이다. 이때 LPC를 통해서 나온 LPC 계수 a_k 는 입력 신호의 스펙트럼 포락선을 표현하며, 식(2)와 같이 전극 필터(all-pole filter)의 주파수 응답에 의해 정의된다.

$$H(z) = \frac{1}{1 - \sum_{k=1}^p a_k z^{-k}}. \quad (2)$$

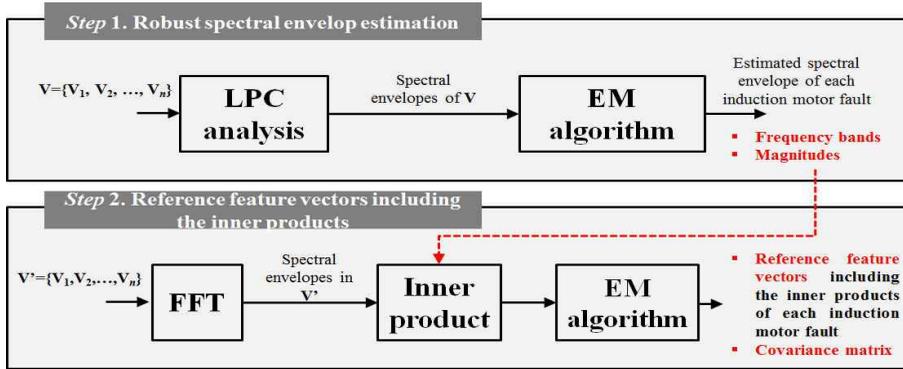


Fig. 2 Generation of reference signature vectors for multiple induction motor faults

3.2. EM 알고리즘

EM 알고리즘은 반복과 정제 과정을 통해 각 객체들이 혼합 모델(mixture model)에 속할 확률을 조정하여 최적의 모델을 생성해 나가는 방법이다⁽¹²⁾.
M차원 데이터

$x = \{x_1, x_2, \dots, x_n\}$, $x_i \in R^M$, $i = 1, 2, 3, \dots, n$ 가 k 개의 클러스터 $z = \{z_1, z_2, \dots, z_k\}$ 를 가진다고 가정하고, $p_j(x_i|\theta_j)$, $j = 1, 2, \dots, k$ 를 파라미터 θ_j 로 표현되는 j 번째 클러스터로터 데이터 x_i 가 생성될 확률 밀도 함수로 정의하면 혼합 모델(mixture model)에 의한 x_i 의 확률 밀도 함수는 식(3)과 같이 정의할 수 있다.

$$p(x_i) = \sum_{j=1}^k \tau_j p_j(x_i|\theta_j), \tau_j \geq 0, \sum_{j=1}^k \tau_j = 1, \quad (3)$$

여기서 τ_j 는 k 개의 확률 밀도 함수 중 j 번째 확률 밀도 함수가 선택될 확률이다. 이때 최대화 하려는 로그 우도 함수(log-likelihood function)는 식(4)와 같다.

$$L_{\log}(\theta_1, \dots, \theta_k; \tau_1, \dots, \tau_k | x) = \sum_{i=1}^n \sum_{j=1}^k c_{ij} [\log((\tau_j p_j(x_i|\theta_j)))] \quad (4)$$

여기서 최대 우도 추정(maximum likelihood estimation)에 의해 식 (7)을 최대화 하는 클러스터 파라미터 $\Theta = \{\theta_1, \theta_2, \dots, \theta_j\}$ 를 구한다. 이때 x_i 는 불완전 데이터로 c_{ij} 를 알 수 없으므로 c_{ij} 의 기댓값을 이용하여 식(4)를 최대화한다. EM 알고리즘은 E(expectation) 단계와 M(maximization) 단계의 두 가지 과정으로 나뉘는데, E 단계에서는 주어진 데이

터 x_i 와 모델 파라미터 $\Theta = \{\theta_1, \theta_2, \dots, \theta_j\}$ 에 대해 c_{ij} 의 기댓값 $\bar{c}_{ij} = E[c_{ij}|x_i, \theta_1, \theta_2, \dots, \theta_j]$ 를 계산한다. 다음으로 M 단계에서는 E 단계에서 구한 기댓값을 이용하여 식(4)의 값을 최대화한다.

3.3. 마할라노비스 거리

마할라노비스 거리는 변수가 2개 이상의 수많은 인자에 대한 집단 사이에 분류를 측정하는 것으로 각 변수 사이에 각 집단의 평균, 공분산을 함께 고려하여 거리를 구하게 되며 식(5)와 같다⁽¹³⁾.

$$MD_i = \sqrt{(x - \mu_i)^T C_i^{-1} (x - \mu_i)}, \quad (5)$$

여기서 x 는 알려지지 않은 집단을 대표할 수 있는 특징 벡터, μ_i 는 i 번째 집단의 특징 벡터에 대한 산술 평균, C_i^{-1} 은 i 번째 집단의 특징 벡터를 이용하여 구한 공분산행렬 C_i 의 역행렬, 그리고 마지막으로 MD_i 는 알려지지 않은 집단을 대표할 수 있는 특징 벡터 x 와 i 번째 집단에 대한 마할라노비스 거리를 각각 나타낸다. 일반적으로 i 번째 집단에 속한 특징 벡터 x 에 대한 MD_i 는 0~2정도로 그 값의 크기가 작으므로, 본 논문에서는 각 결함 유형 사이의 마할라노비스 거리가 최소가 되는 결함 유형을 선택함으로써 유도 전동기 다중 결함 분류가 가능하다.

3.4. 유도 전동기 결함 유형별 참조 특징 벡터 생성

Fig. 2는 유도 전동기 결함 유형별 참조 특징 벡터 추출을 위한 과정으로 크게 두 단계로 나뉜다.

- 단계 1에서는 유도 전동기 결함 유형별 특징 주파수를 포함한 주파수 대역과 그에 상응하는 크

기 정보를 추정하며, 이를 결합 유형별 특징 추출에 활용한다. 2장에서 언급하였듯이 본 논문에서는 결합 유형별 1초 길이의 105개 진동 신호를 취득하였는데, 이 가운데 각 결합 유형별 무작위로 30개의 진동 신호를 선택하여 훈련 데이터로 사용한다. 먼저 각 결합별 30개의 진동 신호에 대한 스펙트럼 포락선을 나타내기 위해 LPC 계수를 구하고, 이에 대한 주파수 응답 결과를 EM 알고리즘의 입력으로 사용한다. 즉 동일한 결합에 대한 스펙트럼 포락선일지라도 유도 전동기의 상태 변화에 따라 그 모양이 미미하게 변하는데, 본 논문에서는 EM 알고리즘을 적용함으로써 관측된 스펙트럼 포락선을 바탕으로 추후 발생할 기댓값이 가장 큰 스펙트럼 포락선을 얻을 수 있다. 이는 결과적으로 시간이 지남에 따라 유도 전동기의 상태 변화, 부하 변동 등으로 인해 발생할 수 있는 스펙트럼 포락선 변화의 영향을 줄이는 효과를 나타낼 수 있다. 마지막으로 EM 알고리즘의 결과를 바탕으로 유도 전동기 결합 유형별 특징 주파수를 포함한 주파수 대역과 그에 상응하는 크기 정보를 추출한다. Fig. 3은 회전자 불균형(RUF) 신호를 대상으로 LPC 분석 및 EM 알고리즘을 적용하여 추정된 주파수 대역과 그 크기 정보를 나타낸다.

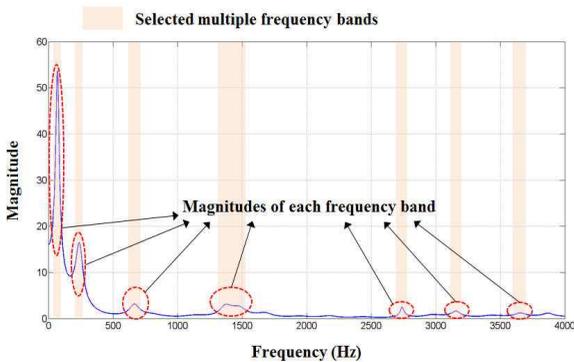


Fig. 3 Selected multiple frequency bands and magnitudes of each frequency using LPC analysis and EM algorithm

- 단계 2에서는 유도 전동기 결합 분류를 위해 사용할 참조 특징 벡터를 추출한다. 먼저 유도 전

동기 결합 유형별 무작위로 선택한 30개의 진동 신호에 대해 고속 푸리에 변환(fast Fourier transform, FFT)을 이용 스펙트럼을 각각 구하고, 단계 1에서 추정된 주파수 대역 및 크기 정보를 이용하여 유도 전동기 각 결합 유형별 내적(inner product)을 구한다. 마지막으로 각 결합 유형별로 구해진 내적은 EM 알고리즘 통해 새롭게 추정되며, 추정된 값은 각 결합 유형을 대표하는 참조 특징 벡터로 사용된다. 또한 마할라노비스 거리 계산을 위해 EM 알고리즘 결과를 이용하여 유도 전동기 각 결합 유형별 공분산행렬(covariance matrix)을 구한다. 본 논문에서 사용하는 각 결합 유형별 특징 벡터의 크기는 결합 유형별로 다를 수 있는데, 이는 특징 주파수를 포함한 스펙트럼 포락선의 모양이 다르기 때문이다. 본 논문에서는 스펙트럼 포락선에서 피크(peak)의 위치를 결합 유형 분류를 위한 특징 주파수로 간주한다.

3.5. 유도 전동기 결합 분류

Fig. 4는 본 논문에서 유도 전동기 결합을 분류하기 위한 처리 과정을 보이며, 각 결합 유형별 1초 진동 신호 105개 중 학습 데이터로 사용한 30개의 신호를 제외한 75개의 신호를 테스트 데이터로 사용한다. 먼저 진동 신호가 결합 분류 시스템으로 입력되면 FFT를 통해 해당 신호에 대한 스펙트럼을 구한다. 구해진 스펙트럼은 각 결합 유형별 특징 추출 및 마할라노비스 거리 계산을 위한 시스템의 입력으로 사용되어 다음과 같은 처리 과정을 거친다.

- 단계 1 : 먼저 3장 4절에서 언급하였듯이 각 시스템은 각 결합 유형별 특징 주파수를 포함한 주파수 대역과 크기 정보를 이용하여 입력된 스펙트럼과의 내적을 구한다.
- 단계 2 : 각 시스템은 유도 전동기 결합 유형별 참조 특징 벡터와 공분산행렬을 가지고 있어 단계 1에서 구한 내적은 식(5)의 x 로, 참조 특징 벡터는 μ 로, 그리고 공분산행렬의 역행렬을 구하여 C^{-1} 로 사용하여 마할라노비스 거리를 각각 구한다.
- 단계 3 : 마지막으로 단계 2에서 구한 마할라노비스 거리 정보를 이용하여 그 거리가 최소가 되는 시스템에 대한 범주로 입력 신호를 분류한다.

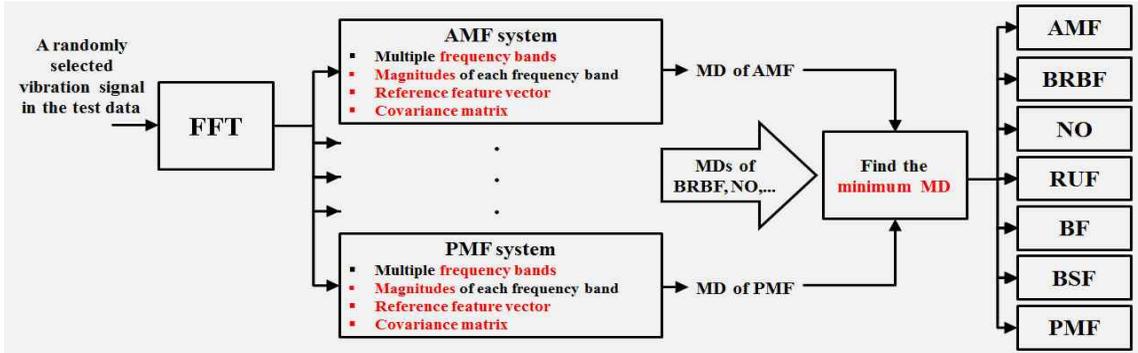


Fig. 4 The proposed fault classification scheme for identifying multiple induction motor faults

Table 2 Mahalanobis distance using the reference feature vector of the RUF

Sample number	Type of faults						
	AMF	BRBF	NO	RUF	BF	BSF	PMF
16	17.44	34.94	14.16	4.07	274.85	197.91	135.65
19	17.36	35.39	14.68	5.75	274.71	198.01	135.38
20	15.95	36.52	15.89	5.15	276.58	195.32	138.04
27	16.25	36.48	14.82	4.96	275.11	198.31	135.27
38	17.14	35.77	14.10	4.45	275.71	197.13	136.25
39	16.04	36.47	15.40	5.48	275.25	195.41	135.27
40	16.68	36.52	15.62	4.76	274.94	195.66	134.40
44	17.31	34.84	14.16	3.99	274.09	196.34	136.21
54	17.39	36.20	14.39	4.43	274.13	196.37	137.49
56	18.17	35.23	14.57	4.91	273.30	198.66	137.56

다. Table 2는 회전자 불균형 진동 신호 10개를 각 시스템의 입력으로 하였을 때 각 시스템의 마할라노비스 거리 값을 나타낸다.

4. 실험 결과

유도 전동기 다중 결함 분류를 위해 본 논문에서는 결함 유형별 1초 길이의 105개 진동 신호를 각각 취득하였다. 이 가운데 30개를 무작위로 선택하여 참조 특징 벡터 생성을 위한 훈련 데이터로 사용하고, 나머지 75개는 테스트 데이터로 사용한다. 제안한 알고리즘의 분류 성능은 식(6)과 같이 분류 정확도를 이용하여 평가한다.

$$CA^i = \frac{CLASSIFY_{correctly}^i}{F_{total}^i} \times 100 (\%), \quad (6)$$

여기서 CA^i 는 i 번째 범주에 속하는 결함에 대한 분류 정확도, F_{total}^i 은 i 번째 범주에 속하는 결함의 수(본 논문에서 $F_{total}^i=75$), $CLASSIFY_{correctly}^i$

는 i 번째 범주에 속하는 결함이 i 번째 범주에 해당하는 결함이라고 판단된 결함의 총 수를 각각 의미한다.

또한 실제 산업현장에서 유도 전동기 진동 신호 취득 시 주변 환경에 의해 잡음이 추가될 가능성이 있으며, 이는 궁극적으로 각 결함 신호의 특징 주파수의 미미한 변화에 기인하는 하나의 요소가 될 수 있다. 센서를 통해 인가되는 잡음은 일반적으로 백색 가우시안 잡음(white Gaussian noise)로 고려되므로 본 논문에서는 취득한 진동 신호에 신호 대 잡음 비(signal-to-noise ratio, SNR)가 20dB와 15dB가 되도록 인위적으로 백색 가우시안 잡음을 추가하여 실험에 함께 사용한다.

Fig. 5는 정상 상태 및 잡음이 인위적으로 추가된 환경에서 제안한 알고리즘과 기존 알고리즘의 분류 성능을 나타낸다. Fig. 5에서 볼 수 있듯이 잡음을 추가하지 않은 환경에서는 두 알고리즘 모두 좋은 분류 성능을 보이고 있으나, 잡음이 추가된 환경에서는 제안한 알고리즘에 비해 기존의 알고리즘의 경

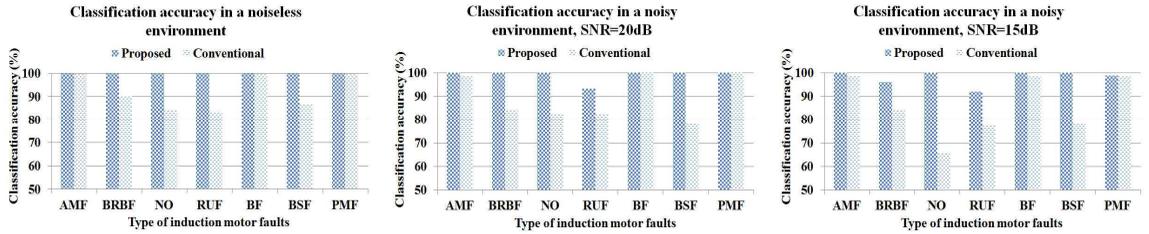


Fig. 5 Classification accuracy of the proposed approach in both a noiseless environment and noisy environments

5. 결론

우 분류 성능이 다소 떨어지는 것을 확인할 수 있다. 제안한 알고리즘의 경우 LPC 분석 기법 및 EM 알고리즘을 이용한 강인한 스펙트럼 포락선을 구하여 결함 분류에 사용함으로써 잡음 환경에서도 각 결함 유형별 마할라노비스 거리 값에 변화가 거의 발생하지 않아 좋은 분류 성능을 보였다. 반면 기존 알고리즘의 경우 1차원 진동 신호를 2차원 그레이 영상으로 변환하고 변환된 영상에 물체의 크기 변환, 회전 등에 강인함을 갖는 지역적 특성 벡터들의 집합으로 변환하는 기법인 SIFT(scale invariant feature transform)를 적용하여 유도 전동기 각 결함 유형별 특징으로 키포인트 기술자(keypoint descriptor)를 추출하였다. 제안한 알고리즘과 유사하게 훈련 데이터로부터 추출한 키포인트 기술자를 참조 데이터로 사용 알려지지 않은 입력 신호로부터 키포인트 기술자를 추출하여 두 키포인트 기술자 사이의 유클리디안 거리(Euclidean distance)의 최솟값을 찾는 방법으로 결함을 분류하였다. 기존 알고리즘의 경우 잡음 환경에서 분류 성능이 다소 떨어지는 이유는 1차원 진동 신호를 2차원 영상 신호로 직접적으로 변환함으로써 영상 정보에 많은 변화가 생겼고 이는 Fig. 6에서와 같이 키포인트 기술자의 큰 변화를 야기하는 결과를 낳았기 때문이다.

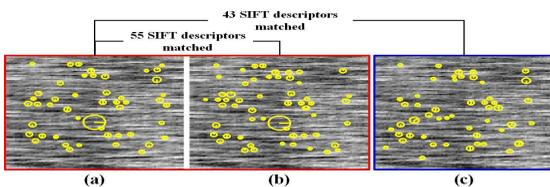


Fig. 6 Variation of SIFT keypoint descriptors in (a) a noiseless environment, (b) a noisy environment (SNR=20dB), and (c) a noisy environment (SNR=15dB)

본 논문에서는 유도 전동기 동작 상태 변화 및 부하의 변동으로 인해 유도 전동기 결함 유형별 특징 주파수를 포함한 스펙트럼 포락선의 변화로 인한 분류 성능 감소를 줄이기 위해 LPC 분석 기법 및 EM 알고리즘을 이용하여 강인한 스펙트럼 포락선을 추정하고, 이를 바탕으로 마할라노비스 거리를 이용하여 결함을 분류하였다. 제안한 알고리즘의 성능 평가를 위해 2011년에 제안한 알고리즘과 분류 정확도 측면에서 성능을 평가하였다. 또한 실제 진동 신호를 취득하는 환경에서 잡음이 포함될 수 있는 가능성을 고려하여 취득한 진동 신호에 백색 가우시안 잡음을 인위적으로 추가하여 성능을 평가하였다. 실험 결과 제안한 알고리즘이 잡음이 없는 환경 및 잡음이 포함된 환경에서 모두 좋은 분류 성능을 보였다.

후 기

이 논문은 2012년도 정부(교육부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것이며 (NRF-2012R1A1A2043644), 또한 산업자원통상부의 광역경제권 선도산업 육성사업의 일환인 “동남광역경제권 선도산업 지원단”의 2013년 연구비 지원으로 수행되었음 (No. R0001220).

참 고 문 헌

- (1) Caesarendra, W., Park, J. H., Kosasih, P. B. and Choi, B. K., 2013, Condition Monitoring of Low Speed Slewing Bearings Based on Ensemble Empirical Mode Decomposition Method. Transactions

of the Korean Society for Noise and Vibration Engineering, Vol. 23, No. 2, pp. 131~143.

(2) Widodo, A., Yang, B. S., Gu, D. S. and Choi, B. K., 2009, Intelligent Fault Diagnosis System of Induction Motors Based on Transient Current Signal. *Mechatronics*, Vol. 19, No. 5, pp. 680~689.

(3) Isermann, R., 2006, *Fault-Diagnosis Systems: An introduction from Fault Detection to Fault Tolerance*. Berlin: Springer, pp.13~43.

(4) Benbouzid, M. E. H., 2000, A Review of Induction Motors Signature Analysis as a Medium for Faults Detection. *IEEE Transactions on Industrial Electronics*, Vol. 47, No. 5, pp. 984~993.

(5) McNerny, S. A. and Dai, Y., 2003, Basic Vibration Signal Processing for Bearing Fault Detection. *IEEE Transactions on Education*, Vol. 46, No. 1, pp. 149~156.

(6) Li, F., Meng, G., Ye, L. and Chen, P., 2008, Wavelet Transform-based Higher-order Statistics for Fault Diagnosis in Rolling Element Bearings. *Journal of Vibration and Control*, Vol. 14, No. 11, pp. 1691~1709.

(7) Widodo, A., Yang, B. S. and Han, T., 2007, Combination of Independent Component Analysis and Support Vector Machines for Intelligent Faults Diagnosis of Induction Motors. *Expert Systems with Application*, Vol. 32, No. 2, pp. 299~312.

(8) Prieto, M. D., Cirrincione, G., Espinosa, A. G., Ortega, J. A. and Henao, H., 2013, Bearing Fault Detection by a Novel Condition-Monitoring Scheme Based on Statistical-Time Features and Neural Networks. *IEEE Transactions on Industrial Electronics*, Vol. 30, No. 8, pp. 3398~3407.

(9) William, P. E. and Hoffman, M. W., 2011, Identification of Bearing Faults Using Time Domain Zero-Crossings. *Mechanical Systems and Signal Processing*, Vol. 25, No. 8, pp. 3078~3088.

(10) Do, V. T. and Chong, U. P., 2011, Signal Model-Based Fault Detection and Diagnosis for Induction Motors Using Features of Vibration Signal in Two-Dimension Domain. *Journal of Mechanical Engineering*, Vol. 57, No. 9, pp. 655~666.

(11) Han, H. S., Cho, S. J. and Chong, U. P., 2011, Neural-Network-based Fault Detection and Diagnosis Method Using EIV(errors-in variables). *Transactions of the Korean Society for Noise and Vibration Engineering*, Vol. 21, No. 11, pp. 1020~1028.

(12) Yu, Jianbo., 2011, Fault Detection Using Principal Components-Based Gaussian Mixture Model for Semiconductor Manufacturing Processes. *IEEE Transactions on Semiconductor Manufacturing*, Vol. 24, No. 3, pp. 432~444.

(13) Xiang, S., Nie, F. and Zhang, C., 2008, Learning a Mahalanobis Distance Metric for Data Clustering and Classification. *Pattern Recognition*, Vol. 41, pp. 3600~3612.