

EMD 기반의 유도 전동기 고장 진단 시스템 개발

Development of EMD-based Fault Diagnosis System for Induction Motor

강 중 순*
Jungsun Kang

(Received June 18, 2014 ; Revised September 3, 2014 ; Accepted September 3, 2014)

Key Words : Induction Motor(유도 전동기), Fault Diagnosis(고장 진단), Empirical Mode Decomposition(경험적 모드 분해), Intrinsic Mode Function(고유 모드 함수), Neural Network(신경회로망)

ABSTRACT

This paper proposes a fault diagnosis system for an induction motor. This system uses empirical mode decomposition(EMD) to extract fault signatures and multi-layer perceptron(MLP) neural network to facilitate an accurate fault diagnosis. EMD can not only decompose a signal adaptively but also provide intrinsic mode functions(IMFs) containing natural oscillatory modes of the signal. However, every IMF does not represent fault signature, an IMF selection algorithm based on harmonics and their energy of each IMF is proposed. The selected IMFs are utilized for fault classification using MLP and this system shows approximately 98 % diagnosis accuracy for the fault vibration signal of the induction motor.

1. 서 론

유도 전동기는 산업 현장에 널리 사용되는 핵심적인 기기 중 하나로써, 효율적인 유지 및 보수는 경제적, 산업적 측면에서 매우 중요하다. 지난 수십 년간 유도 전동기의 효율적인 유지, 고장 검출 및 진단 시스템에 대한 연구는 지속적으로 이루어졌다⁽¹⁻⁸⁾. 유도 전동기 고장 진단 시스템은 일반적으로 센서로부터 신호를 취득하고 적절한 신호처리 방법을 이용해 유용한 특징들을 추출하여 인공지능을 통해 고장의 유형을 진단한다.

산업용 전동기 고장은 크게 전기적 결함과 기계적 결함으로 분류할 수 있다. 이들의 고장 신호와 관련 방법에 대해서는 이미 자세하게 분류하여 보고

된 바가 있다⁽⁹⁾. 예를 들어, 전동기 고정자 전류는 고정자, 회전자, 베어링 고장 검출 연구 등에서 많이 사용되고 있다. 값싼 전류 센서와 외부의 영향을 최소화한 신호 취득 기술이 이를 이용한 상태 모니터링 시스템을 가장 유용한 시스템으로 만든 것이다. 대표적인 기술이 MCSA(motor current signature analysis)이다⁽¹⁰⁾. 기계적 결함에 유용한 진동을 이용한 고장 진단은 가장 오래된 상태 모니터링 기술 중 하나이다. 베어링, 회전자, 편심과 관련된 고장의 이상 신호에 대해 진동 신호의 스펙트럼 분석 방법도 잘 알려져 있다⁽¹¹⁻¹³⁾. 이밖에 전기적 결함에 대해 진동 신호 분석을 통한 모델 기반의 기술이 제안되기도 하였다⁽¹⁴⁾.

인공지능은 고장 진단의 자동화에 효율적으로 사용되는 기술이다. 비록 이 기술이 초기 학습을 통해

* Corresponding Author ; Member, School of Electricity & Electronics, Ulsan College
E-mail : jskang@uc.ac.kr
Tel : +82-52-279-3212

‡ Recommended by Editor SungSoo Na

© The Korean Society for Noise and Vibration Engineering

최적화된 데이터가 필요하다 할지라도 유지보수 인력의 감축과 빠르고 자동화된 고장 검출을 효율적으로 이룰 수 있다는 사실에는 변함이 없다. 신경회로망, 퍼지 논리, 신경망-퍼지, 그리고 유전자 알고리즘을 이용한 전동기 고장 진단 기술에 대해서는 X. Z. Gao의 1명이 명확하게 요약, 보고한 바 있다⁽¹⁵⁾.

고장 진단 기술은 진단 과정에 따라 크게 모델 기반 기술, 신호 기반 기술, 그리고 데이터 기반 기술로 나눌 수 있는데, 신호 처리 기술은 이들 세 가지 기술 모두에서 그 영향력과 역할이 조금 다를지라도 매우 중요한 부분을 차지하고 있다. 신호 처리 기술은 사용되는 영역에 따라 시간 영역 분석, 주파수 영역 분석, 그리고 시간-주파수 영역 분석으로 나뉜다.

시간-주파수 영역의 신호 분석 방법 중 STFT (short-time Fourier transform)는 윈도우를 이용하여 대상 신호를 짧은 시간으로 쪼갬으로써 비선형 (nonlinear) 신호를 짧은 시간 내 선형신호로 간주하여 분석한다. 이 방법은 신호의 전체적인 특성을 분석할 때는 적합하나, 신호의 천이(transition)와 같은 순간의 변화를 분석할 때는 적합하지 않다. CWT (continuous wavelet transform)는 신호의 천이와 같은 비선형적인 특성을 분석할 수 있지만 이 또한 주어진 기저 함수와의 직교성에 기반한 방법으로 기저 함수의 종류에 따라 분석 결과가 달리 나타난다. 몇몇 진동 기반의 고장 진단 전문가 시스템에서 STFT 또는 CWT 기반의 신호처리 기술을 사용했으나⁽¹⁶⁾ 비정상 상태(nonstationary)와 비선형 고장 신호 분석에는 적합하지 못하였다. N. E. Huang은 이러한 신호를 분석할 수 있는 EMD(empirical mode decomposition) 알고리즘을 제안하였다⁽¹⁷⁾. 이 방법은 신호의 통계적 특성을 기반으로 그 신호가 가진 IMF(intrinsic mode function)를 추출하는 방식이라서, 신호의 종류나 기저함수의 종류에 따른 제한이 없다. 또한 신호의 천이와 같은 비선형성이 IMF에 그대로 유지된다⁽¹⁷⁾.

최근에는 발전소와 같은 산업설비로부터 발생한 신호와 음악과 같이 악기에서 발생한 신호를 EMD로 분석하는 연구가 수행되었다⁽¹⁸⁻²¹⁾. 하지만 이 알고리즘도 고장진단 분야에 바로 적용하기엔 몇몇 제한점이 있다. EMD가 종종 불필요한 IMF를 만들어 내기 때문인데 만약 이러한 단점을 극복할 수 있다면 EMD는 전동기 고장 진단 분야에 훨씬 많이 사

용될 수 있을 것이다. 이에 이 논문에서는 유도 전동기의 고장 신호 분석하기 위해 EMD에 의해 추출된 IMF 중 중요한 IMF를 선별하고, 이들 신호의 특징을 신경회로망에 적용시킨 고장진단 시스템에 대해 살펴볼 것이다.

2. 배경이론

2.1 IMF

IMF는 다음의 두 가지 조건을 갖춘 함수로 정의한다. (i) 주어진 전체 데이터에서 극값의 개수와 영교차점의 개수가 동일하거나 단 한개만 차이난다. (ii) 임의의 점에서 국부 극소값의 포락선과 국부 극대값의 포락선의 평균값이 '0'이다. 영교차 관련 정의로부터 IMF는 단 하나의 진동 모드를 갖게 되고, 또한 정의로부터 IMF는 협대역 신호(narrow band signal)로 제한되지 않으며 크기와 주파수 변조가 될 수 있다. 사실상 이것은 비정상 상태를 의미한다. 결론적으로, 복잡한 데이터의 임의 국부 시간에 하나 이상의 순간 주파수가 나타날 수 있으며 이를 분석하기 위해서는 EMD 방법이 필요하다⁽¹⁷⁾.

2.2 EMD

EMD는 다음의 세 가지 가정으로 시작한다. (i) 신호는 최소 두개의 극값을 갖는다. (ii) 특정 시간 스케일(characteristic time scale)은 극값들 간의 시간경과에 의해 정의된다. 여기서 특정 시간 스케일은 진동 모드, 즉 고유한 주파수를 결정하는 요소이다. (iii) 만약 데이터에 극값이 전혀 없고 단지 굴절 지점만 있다면, 극점을 찾기 위해 한 번 또는 그 이상 미분을 수행할 수 있다.

EMD의 가장 핵심 단계는 여과 과정(sifting process)이다. 이는 IMF의 정의에 의한 분해법으로 국부 극대값과 국부 극소값의 포락선을 이용하여 간단하게 수행된다. 단계는 다음과 같다⁽¹⁷⁾.

단계 1 : 극값들이 결정되면, 3차 보간 함수(cubic spline)를 이용하여 극대, 극소값의 포락선을 그린 후, 이 포락선들의 평균 m_1 을 구한다.

단계 2 : 데이터 $x(t)$ 와 m_1 의 차이가 첫 번째 요소 h_1 이 된다. $\rightarrow x(t) - m_1 = h_1$

단계 3 : 단계 1부터 2까지를 반복한다. $\rightarrow h_1 - m_{11} = h_{11}$

단계 4 : 반복을 거듭할수록 국부 극대는 모두 양의 값을, 국부 국소는 모두 음의 값을 갖게 된다.

$$\rightarrow h_{1(k-1)} - m_{1k} = h_{1k}$$

단계 5 : 파형이 대칭이 될 때 까지 반복하여 첫 번째 IMF의 성분을 찾는다. $\rightarrow c_1 = h_{1k}$

단계 6 : 여과 과정을 멈추기 위한 [평가기준 1] : 두 번의 연속된 여과 과정의 결과로 계산한 표준 편차(SD)의 값이 0.2-0.3일 때 반복을 멈춘다. \rightarrow

$$SD = \sum_{t=0}^T \left[\frac{|h_{1(k-1)}(t) - h_{1k}(t)|^2}{h_{1(k-1)}^2(t)} \right]$$

단계 7 : c_1 은 신호의 가장 짧은 주기를 갖는 요소이다. 원 신호로부터 c_1 을 제거하면 잔여신호 r_1 을 구할 수 있다. $\rightarrow x(t) - c_1 = r_1$

단계 8 : r_1 에는 더 긴 주기를 갖는 요소를 포함하고 있으므로, 이로부터 두 번째 IMF 성분 c_2 를 구하고 이를 제거하면 잔여신호 r_2 를 구할 수 있다. 단계 1부터 단계 7까지를 반복한다. $\rightarrow r_1 - c_2 = r_2, \dots, r_{n-1} - c_n = r_n$

단계 9 : 여과 과정을 멈추기 위한 [평가기준 2] : r_n 이 더 이상 IMF를 추출할 수 없는 단조함수가 된 경우 멈춘다.

단계 10 : 최종적으로 n 개의 IMF와 잔여신호 r_n (상수 값을 갖거나 평균의 경향을 나타냄)으로 분해

$$\text{할 수 있다.} \rightarrow x(t) = \sum_{i=1}^n c_i + r_n$$

3. 제안하는 방법

앞서 설명했듯이, EMD는 종종 불필요한 IMF를 만들어 내는데, 이를 극복하기 위해 N. E. Huang은 그의 연구에서 몇 가지 방법을 제안하였고⁽²²⁾, 이 논문에서도 이를 다음과 같이 적용하였다.

[평가기준 1]의 수정 : 각 여과 과정의 반복 횟수를 10으로 제한한다.

[평가기준 2]의 수정 : IMF의 개수 = $\lfloor \log_2 N \rfloor$ 로 제한한다. 여기서 N 은 데이터의 샘플 수이다.

위와 같이 EMD를 개선하여 사용하였다고 하여 이를 통해 얻은 모든 IMF가 주요 IMF라는 의미는 아니다. 다시 말하면 이들 모두가 고장 특징을 포함한 주요 신호가 아니라는 의미이다. 오히려 이들은 데이터에 존재하는 노이즈를 나타내거나 원하지 않

는 진동을 포함하거나 또는 3차 보간법의 부수적인 영향과 모드의 혼합 또는 EMD가 본질적으로 포함하고 있는 끝점 효과를 표현하고 있을 수도 있다. 일반적으로 불필요한 IMF들은 전문가의 시각적 또는 경험적 평가 기준에 의해 제거되는데 이 방법은 수동적이고 전문가와의 상호 작용이 필요하다⁽²³⁾. 이러한 전문가 상호 작용 이슈를 제거하기 위해 몇몇 논리적인 가정에 기반을 둔 IMF 선택 알고리즘을 제안한다.

유도 진동기의 고장 특징이 잘 드러난 주요 IMF로 선택된 것들은 몇 가지 특징을 갖고 있다. 첫 번째 특징은 정상 신호에 비해 상대적으로 높은 에너지를 갖는다는 것이다. 즉, 고장의 경우, 정상적인 경우보다 고장을 나타내는 진동이 두드러진다는 것이다. 두 번째 특징은 특정 진동 응답의 배음성분에 관한 것으로 대부분의 고장은 특정 주파수와 몇몇 배음 성분이 두드러진다는 것이다. EMD의 이분적 필터 बैं크(dyadic filter bank) 본질에 의해 이들 배음 성분의 일부는 낮은 인덱스의 IMF의 스펙트럼에서 관찰될 것이고 기본 성분은 높은 인덱스의 IMF에서 찾을 수 있을 것이다. 이러한 사실을 고려할 때, IMF가 포함하고 있는 배음의 에너지는 주요 IMF를 찾는데 효과적일 것이다. 이를 이용한 IMF 선택 알고리즘은 다음과 같다.

단계 1 : 각각의 IMF c_j 에 대해 평균 에너지 E_j 를 계산하고 1차적으로 IMF를 선별할 에너지의 임계값을 식(1)과 같이 계산한다.

$$E_{th} = \text{mean}\{E_p\} \tag{1}$$

여기서 $E_p \in \{E_j | E_j \leq \text{mean}\{E_j\}\}$.

단계 2 : $E_j > E_{th}$ 를 만족하는 IMF에 대해 푸리에 스펙트럼을 계산하고 직류 성분만 포함하고 있는 IMF는 제외시킨다. $\rightarrow C_j(\omega) = FT\{c_j\}$

단계 3 : 스펙트럼 중 $C_{\max(j)}$ 의 평균 크기보다 큰 피크들의 주파수 ω_k 에 대하여 임펄스 열을 식(2)과 같이 구한다.

$$\delta_k(\omega) = \begin{cases} 1, & \omega = \omega_k, 2\omega_k, 3\omega_k, \dots \\ 0, & \text{otherwise} \end{cases} \tag{2}$$

여기서 $k = 1, 2, \dots, s$ 이다.

단계 4 : 단계 2에서 선택된 각각의 IMF가 포함

하고 있는 배음의 에너지를 식 (3)과 같이 계산한다.

$$H_j = \sum_{k=1}^s \delta_k(\omega) \cdot C_j(\omega) \quad (3)$$

단계 5 : H_j 를 내림차순으로 정렬하여 m 개의 IMF를 선택한다. m 은 사용자가 미리 설정한 최종 IMF의 개수이다.

이 논문에서 IMF의 개수 m 은 신경회로망의 입력 개수와 관련이 있기 때문에 고장 진단 시스템의 사이즈를 고려하여 사용자가 최적의 값을 결정할 수 있다. 이렇게 선별된 각 고장 신호별 m 개의 IMF로부터 구한 평균(mean), 분산(variance), 첨도(kurtosis), 왜도(skewness)를 MLP(multi-layer perceptron) 신경회로망의 특징 벡터로 사용한다.

4. 실험 및 결과

실험에 사용된 진동 데이터는 6개의 유도 전동기 (0.5 kW, 60 Hz, 4극)에 각각 정상 데이터(normal, NOR)와 정렬불량(misalignment, MIS), 베어링 결함 (faulty bearing out race, FBO), 회전봉 파손(broken rotor bar, BRB), 굽은 회전축(bowed rotor shaft, BRS), 회전자 불평형(rotor unbalance, RUN) 고장을 인위적으로 발생시켜 취득한 데이터로서^(5,6) 각 고장 데이터에 대한 자세한 설정은 Table 1과 같으며 실험 환경은 Fig. 1과 같다. 샘플링 주파수는 8 kHz이며, 학습과 테스트를 위한 충분한 데이터 집합을 만들기 위하여 취득 데이터를 2.1333초 길이의 프레임으로

나누어 각 상태별로 100개의 데이터를 추출하여 사용하였다^(5,6). 이들 데이터는 EMD를 거쳐 각 데이터마다 14개($\text{round}(\log_2(8000 \times 2.1333)) = 14$)의 IMF가 생성된다. 제안한 알고리즘에 의거하여 이들 중 배음의 에너지가 높은 순서로 6개를 선택하여 MLP 신경회로망에 사용하였다. Table 2는 RUN 고장 데이터에 대해 제안한 IMF선택 알고리즘의 결과를 예로 보인 것이다.

이 논문에서는 MLP 신경회로망을 이용한 다른 연구^(5,6)에서와 마찬가지로 은닉층의 개수는 1개를 설정하였다. 다만, 기존 연구와는 달리 은닉층의 뉴런의 개수는 3개로 결정하였는데 이는 경험적으로

Table 1 Experimental condition

Type	Fault condition
NOR	Normal condition: without fault
MIS	Angular(0.48°) misalignment
FBO	A spalling on the outer raceway
BRB	Dent(diameter: 5 mm, depth : 15 mm) on the 12 rotor bar
BRS	Deflection(0.075 mm) on the center of the rotor shaft
RUN	Unbalance mass(8.4 g) on the rotor

Table 2 Example of IMF selection result in the case of RUN

IMF index	$E_j (\times 10^{-2})$	$H_j (\times 10^{-6})$	DOI	Selection
1	0.243	0.028	7	
2	0.093	-	-	
3	0.321	0.074	5	○
4	1.268	0.438	2	○
5	1.469	0.345	4	○
6	5.562	1.877	1	○
7	2.271	0.384	3	○
8	0.835	0.029	6	○
9	0.181	-	-	
10	0.095	-	-	
11	0.046	-	-	
12	0.037	-	-	
13	0.040	-	-	
14	0.062	-	-	

E_{th} : 0.195×10^{-2} , DOI: descending order of IMF index



Fig. 1 Experimental apparatus

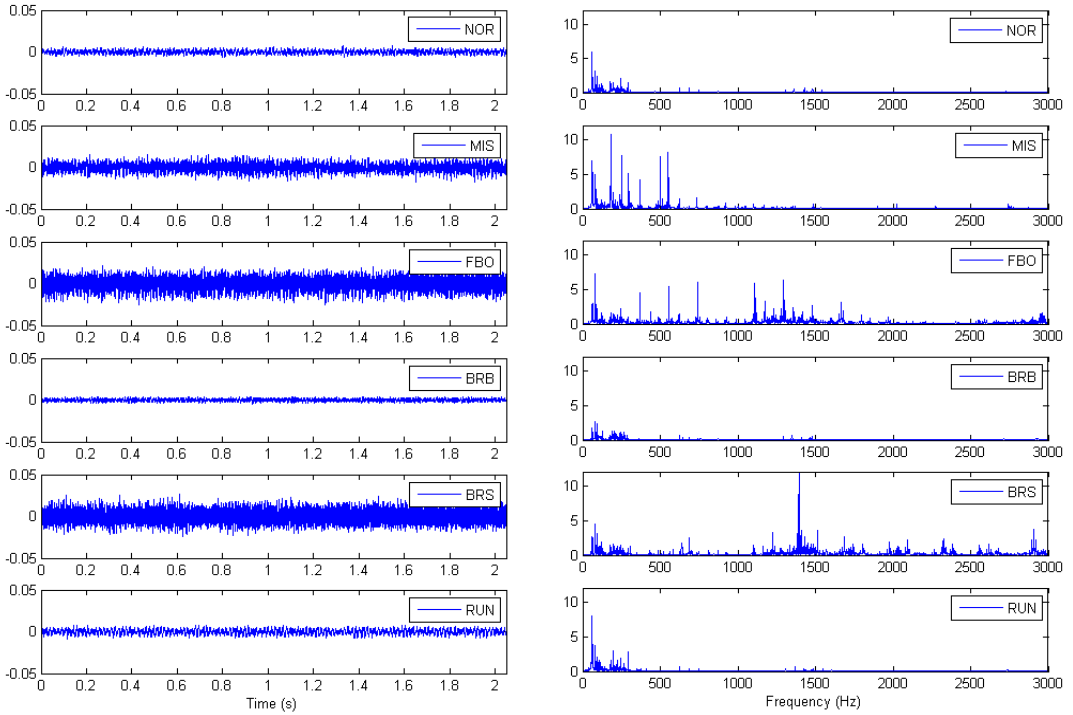


Fig. 2 Fault signals in time domain(left) and frequency domain(right)

결정한 값이다. 각각의 상태별 진동 데이터로부터 추출한 6개의 IMF로부터 각각 4개의 통계값을 계산하여 총 24개의 값이 입력으로 사용되었다. 이렇게 추출한 특징벡터의 80%를 학습 데이터로 20%를 테스트 데이터로 나누었고 MLP 신경회로망의 설계 및 학습은 Matlab 8.0의 Neural Network Toolbox를 이용하였다.

제안한 고장 진단 시스템은 시간-주파수 영역의 분석법인 EMD를 기반으로 한다. 따라서 같은 유형의 분석법을 사용하는 시스템과 성능을 비교하기 위하여 DWT(discrete wavelet transform) 기반의 고장 진단 시스템⁽⁴⁾과 성능을 비교하였다. Table 3과 Table 4는 각각 제안한 시스템과 DWT기반 고장 시스템의 분류 결과이다. 각각의 고장에 대해 제안한 시스템은 약 86%~90%의 분류 결과를 보였고, DWT기반 시스템의 경우 약 79%~83%의 분류 결과를 보여 제안한 시스템이 대략 7%의 우수한 분류율을 보였다. 하지만 이러한 분류 결과의 단순 비교보다 더 주목해야 할 점은 각 고장을 정상으로 잘못 분류한 경우인데, 왜냐하면 실제 현장에서 고장이

Table 3 Diagnosis result by proposed method

		Classification rate(%)					
		MIS	BRS	BRB	FBO	NOR	RUN
Types of fault data	MIS	89.498	2.940	1.020	2.120	3.128	1.294
	BRS	1.990	87.808	1.798	3.172	3.296	1.936
	BRB	0.904	2.066	87.922	1.526	4.818	2.764
	FBO	2.908	3.604	1.386	86.782	2.568	2.752
	NOR	0.628	1.756	3.386	1.568	89.764	2.898
	RUN	1.104	2.662	2.298	2.510	4.620	86.806

Table 4 Diagnosis result by DWT

		Classification rate(%)					
		MIS	BRS	BRB	FBO	NOR	RUN
Types of fault data	MIS	81.258	2.838	4.315	2.492	5.459	3.638
	BRS	2.811	83.096	3.392	4.231	4.361	2.109
	BRB	3.398	2.979	81.595	2.045	7.595	2.388
	FBO	2.854	4.213	2.801	83.424	3.811	2.897
	NOR	4.213	2.517	6.844	2.425	78.968	5.033
	RUN	5.118	2.488	3.682	3.048	6.19	79.474

Table 5 Comparison of results(unit : %)

	Proposed	DWT
ACR	88.097	81.303
P(N F ^c)	82.966	74.229
P(W F)	97.919	95.739

ACR: average of classification rate

발생했음에도 불구하고 이를 정상으로 알려준다면 경제적 측면을 포함한 모든 측면에서 손해가 막대할 수 있기 때문이다. Table 3과 Table 4를 단순히 비교하더라도 제안한 시스템이 DWT기반 시스템보다 오분류율이 낮음을 알 수 있지만 정확한 분석을 위해 다음의 4가지 경우 대해 살펴보았다.

- (1) 고장이 발생했는데 실제 고장일 확률 : P(W|F)
- (2) 고장이 발생했는데 정상일 확률 : P(N|F)
- (3) 고장이 발생하지 않았는데 고장일 확률 : P(W|F^c)
- (4) 고장이 발생하지 않았는데 실제로 정상일 확률 : P(N|F^c)

여기서 P(F)는 고장이 발생할 확률, W는 고장, N은 정상인 경우이다. 위의 4가지 경우 중 첫 번째는 시스템의 고장 진단 성능을 나타내는 것이고, 네 번째 경우는 오분류율과 관계된 지표이다. 계산을 위해 각 고장은 동일한 확률로 발생한다고 가정하였고 결과는 Table 5에 나타내었다. 고장 진단 성능은 제안한 시스템이 약 2%정도 우수한 것으로 나왔으나, 오분류율은 8%이상 개선된 것을 알 수 있다.

5. 결 론

이 논문에서는 시간-주파수 분석법인 EMD를 이용하여 고장 신호를 IMF로 분해하고, 이들을 배음과 에너지를 기준으로 각 IMF의 중요도를 결정하였다. 중요도가 높은 순서로 선별된 IMF는 MLP 신경회로망의 사이즈에 따라 개수가 결정되었으며 각각의 IMF로부터 평균, 분산, 첨도, 왜도를 계산하여 특징벡터로 사용하였다. 이렇게 설계된 고장진단 시스템은 고장 진단율의 정확도가 약 98%였으며 특히 DWT를 기반으로 한 고장진단 시스템보다 오분류율은 8%이상 개선할 수 있었다.

신경회로망을 이용한 시스템은 경험적인 파라미터를 사용하여 시스템을 구성하는 경우가 많다. 이 논문에서도 은닉층의 개수, 은닉층의 뉴런의 개수,

특징벡터의 개수를 모두 경험적으로 판단, 또는 다른 연구로부터 인용하여 사용하였다. 향후 이렇게 MLP 신경회로망의 사이즈를 결정하는 파라미터들과 성능의 관계를 규명하여 최적화된 고장 진단 시스템 설계에 대한 연구가 필요할 것이다. 더불어 IMF를 선택하는 알고리즘의 개선에 대한 연구도 필요할 것이다.

References

- (1) Yang, B.-S., Kim, K. J. and Han, T., 2004, Fault Diagnosis of Induction Motors Using Data Fusion of Vibration and Current Signal, Transactions of the Korea Society for Noise and Vibration Engineering, Vol. 14, No. 11, pp. 1091~1100.
- (2) Lee, S.-S., Cho, S.-J. and Chong, U.-P., 2005, Fault Diagnosis System of Rotating Machines Using LPC Residual Signal Energy, Journal of the Institute of Signal Processing and System, Vol. 6, No. 3, pp. 143~147.
- (3) Chong, U.-P., Cho, S.-J. and Lee, J.-Y., 2006, Fault Diagnosis for Rotating Machine Using Feature Extraction and Minimum Detection Error Algorithm, Transactions of the Korea Society for Noise and Vibration Engineering, Vol. 16, No. 1, pp. 27~33.
- (4) Tuan, D. V., 2009, Fault Detection and Diagnosis for Induction Motors Using Local Feature, Variance, Cross-correlation and Wavelet, Ph.D. thesis, University of Ulsan.
- (5) Han, H.-S., Cho, S.-J. and Chong, U.-P., 2010, Feature Vector Decision Method of Various Fault Signals for Neural-network-based Fault Diagnosis System, Transactions of the Korea Society for Noise and Vibration Engineering, Vol. 20, No. 11, pp. 1009~1017.
- (6) Han, H., Cho, S. and Chong, U., 2011, Neural-network-based Fault Detection and Diagnosis Method Using EIV(errors-in-variables), Transactions of the Korea Society for Noise and Vibration Engineering, Vol. 21, No. 11, pp. 1020~1028.
- (7) Yang, B. S., Han, T. and Yin, Z. T., 2006, Fault Diagnosis System of Induction Motor Using Feature Extraction, Feature Selection and Classification Algorithm, JSME International Journal Series C., Vol.

49, No. 3, pp. 734~741.

(8) Wen, X., 2011, A Hybrid Intelligent Technique for Induction Motor Condition Monitoring, Ph.D. thesis, University of Portsmouth.

(9) Nandi, S., Toliyat, H. A. and Li, X., 2005, Condition Monitoring and Fault Diagnosis of Electrical Motors-a Review, IEEE Transactions on Energy Conversion, Vol. 20, No. 4, pp. 719~729.

(10) 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.

(11) Vas, P., 1996, Parameter Estimation, Condition Monitoring and Diagnosis of Electrical Machines, Oxford, Clarendon, U.K.

(12) Muller, G. H. and Landy, C. F., 2003, A Novel Method to Detect Broken Rotor Bars in Squirrel Cage Induction Motors when Interbar Currents are Present, IEEE Transactions on Energy Conversion, Vol. 18, No. 1, pp. 71~79.

(13) Dorrell, D. G., Thomson, W. T. and Roach, S., 1997, Analysis of Airgap Flux, Current and Vibration Signals as a Function of the Combination of Static and Dynamic Airgap Eccentricity in 3-phase Induction Motors, IEEE Transactions on Industry Applications, Vol. 33, No. 1, pp. 24~34.

(14) Su, H., Chong, K. T. and Kumar, R. Ravi, 2011, Vibration Signal Analysis for Electrical Fault Detection of Induction Machine Using Neural Networks, Neural Computing & Applications, Vol. 20, No. 2, pp. 183~194.

(15) Gao, X. Z. and Ovaska, S. J., 2001, Soft Computing Methods in Motor Fault Diagnosis, Applied Soft Computing, Vol. 1, No. 1, pp. 73~81.

(16) Bellini, A., Filippetti, F., Tassoni, C. and Capolino, G.-A., 2008, Advances in Diagnostic Techniques for Induction Machines, IEEE Transactions on Industrial Electronics, Vol. 55, No. 12, pp. 4109~4126.

(17) Huang, N. E., Shen, Z., Long, S. R., Wu, M., Shih, H., Zheng, N., Yen, C., Tung, C. C. and Liu, H. H., 1998, The Empirical Mode Decomposition and the Hilbert Spectrum for Non-linear and Non-stationary

Time Series Analysis, Proceedings of the Royal Society London. Series A, Mathematical and Physical Sciences. Vol. 454, pp. 903~995.

(18) Bassiuny, A. M. and Li, X., 2007, Flute Breakage Detection During End Milling Using Hilbert-Huang Transform and Smoothed Nonlinear Energy Operator, International Journal of Machine and Tools Manufacture. Vol. 47, No. 6, pp. 1011~1020.

(19) Yang, W.-X., 2008, Interpretation of Mechanical Signals Using an Improved Hilbert-Huang Transform, Mechanical Systems and Signal Processing, Vol. 22, No. 5, pp. 1061~1071.

(20) Cho, S., 2013, Analysis of the Jing Sound Using Empirical Mode Decomposition, Proceedings of Spring Conference of Acoustical Society of Korea, pp. 66~69.

(21) Cho, S., 2013, Intrinsic Frequency Analysis for the Percussion Instrument based on the Recorded Sound, Proceeding of Summer Conference of Institute of Signal Processing and System, pp. 89~91.

(22) Wang, G., Chen, X., Qiao, F., Wu, Z. and Huang, N. E., 2010, On Intrinsic Mode Function, Advances in Adaptive Data Analysis, Vol. 2, No. 3, pp. 277~293.

(23) Ricci, R. and Pennacchi, P., 2011, Diagnostics of Gear Faults based on EMD and Automatic Selection of Intrinsic Mode Functions, Mechanical System and Signal Processing, Vol. 25, No. 3, pp. 821~838.

(24) Widodo, A. and Yang, B.-S., 2007, Application of Nonlinear Feature Extraction and Support Vector Machines for Fault Diagnosis of Induction Motors, Expert Systems with Applications, Vol. 33, pp. 241~250.



Jungsun Kang is a professor in School of Electricity & Electronics, Ulsan College. He received his Ph.D. degree in Electronic Engineering from Mongolian University of Science & Technology in 2009. His research interests include communication, signal analysis/synthesis and neural network.