

# 전류 및 자속센서를 이용한 유도전동기 예방진단 알고리즘 개발에 관한 연구

## Study on the Development of Diagnosis Algorithm for Induction Motor Using Current and Magnetic Flux Sensors

한 상 보\*<sup>★</sup>

Sang-Bo Han\*<sup>★</sup>

### Abstract

This paper discussed the results of the development and application of the machine learning algorithm to the induction motor for the preventive diagnostic system using current and magnetic flux signals. The optimal 29 features were extracted for identifying faulted types of induction motor. In particular, any load rate was derived using the tendency of the difference value from the center of the 7th harmonic frequency to the sideband of the current signal, and the corresponding classification accuracy showed about 84.6% by the KPCA feature reduction technique and the k-NN determination algorithm.

### 요 약

본 논문은 전류신호와 자속신호를 이용한 유도전동기 예방진단시스템을 개발하기 위한 머신러닝 알고리즘의 개발 및 적용 결과에 대하여 논하였다. 유도전동기의 결함 종류를 판별하기 위한 최적 특징추출단계를 통하여 총 29개의 특징을 도출하였다. 특히, 전류신호의 제7차 고조파 중심으로부터 사이드밴드까지의 주파수의 차이가 부하율 증가에 따라서 증가되는 경향을 이용하여 임의의 부하율 상태를 반영할 수 있는 알고리즘을 도출하였으며, KPCA 특징 축소 기법, k-NN 판단 알고리즘에 의한 분류 정확도를 조사한 결과, 약 84.6%의 분류 정확도를 보였다.

*Key words : Current, Diagnostic system, Induction motor, Magnetic flux, Machine learning*

### 1. 서론

최근, 초고속 인터넷이 널리 보급되고 통신속도가 5G로 매우 빨라지면서 다양한 종류의 스마트 센서기반 사물인터넷에 의해 수많은 데이터가 생성되고, 생성된 데이터들을 활용한 인공지능(Artificial Intelligence), 머신러닝(Machine Learning), 딥러닝

(Deep Learning) 기법에 의하여 사회, 경제, 문화 등 모든 분야에서 크게 변화되고 있다. 따라서, 산업체의 수많은 시스템을 실시간으로 편리하게 제어하고 다양한 기능을 갖추기 위한 연구 및 개발이 활발히 진행되고 있다[1]~[8].

특히, 산업체 자동차, 반도체, 뿌리산업과 같은 대규모 산업공정에 사용되는 전력변환기, 자기장

\* Dept. of Electrical Engineering, Kyungnam University

★ Corresponding author

E-mail : [hansangbo@uok.ac.kr](mailto:hansangbo@uok.ac.kr), Tel : +82-55-249-2635

Manuscript received Oct. 24, 2019; revised Nov. 17, 2019; Nov. 21, accepted 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

발생장치, 회전기기 등과 같은 비선형 부하들은 교류전원의 선형적 특성을 변화시킬 수 있으며, 갑작스런 고장은 공정지연 및 제품 품질저하로 막대한 경제적 손실을 초래할 수 있다.

최근, 회전기기류의 정상 및 고장 상태를 정확히 예지 및 진단하기 위하여 전류, 전압, 온도, 진동 등의 신호들을 이용한 많은 방법들이 개발되어 실제 산업현장에서 적용되고 있으며, 그 중에서도 진동 신호를 이용한 진단시스템이 널리 이용되고 있다. 그러나, 이러한 진동신호에 의한 결함 추출도 결함 종류에 따라 분류 한계가 있으므로, 여러 센서를 복합화하여 최적 시스템을 개발하기 위한 연구도 진행되고 있다.

아울러, 결함이나 고장을 추출하기 위한 신호처리 기법과 추출된 특징에 근거한 이상상태 예지 및 진단을 행하는 다양한 패턴 인식법이 연구되고 있으며, 초기 결함이 있을 경우에는 결함신호가 간헐적으로 존재하므로 이러한 비정규적 신호를 측정하기 위해 웨이블릿 변환에 의해 미세신호를 분리하는 방법도 제안되어 있다[9].

특히, 회전기기와 같이 부하용량이 가변됨에 따라 출력이 변화되는 경우에 있어서는 사용된 센서들의 특징값도 부하용량 변화에 따라 변화되므로 각 센서의 특징값 변화경향을 정확히 반영해야만 올바른 진단이 가능하다.

본 연구에서는 전동기의 주요한 고장 중에서 대표적 6가지 고장모의 전동기를 그 정도에 따라서 2 단계(경미, 심각)로 분류하여 총 12개 전동기를 제작하고, 전동기 전원공급 전류 센서 3개와 공극의 유기기전력을 측정하는 자속센서를 이용하여 시계열 데이터를 반복·측정하였다. 이렇게 측정된 데이터를 이용하여 자체 개발한 머신러닝 알고리즘에 적용하여 고장 분류 정확도에 대하여 논하고, 추출된 특징과 함께 예방 진단 알고리즘의 우수성을 평가하였다.

또한, 훈련과정에서 부하율의 변화에 따른 특징값들의 변화된 값을 자동으로 계산될 수 있도록 수식화함으로써 테스트 과정의 임의 부하율에 대하여 고장분류 정확도를 높이도록 구성하였다.

## 2. 측정 시스템 및 알고리즘 구성

### 2.1 실험장치 및 측정 방법

전동기의 주요한 고장은 베어링 불량, 회전자 바

손상, 고정자 권선단락, 샤프트 변형, 회전자 편심 등을 들 수 있다[10]~[18]. 주요한 고장인 6가지를 모의하기 위하여 경미 및 심각한 고장상태인 12개 전동기와 정상상태 전동기를 포함하여 13개의 3상 7.5[kW](380V, 4극) 전동기를 고장모의 제작하였다. 사용된 결함 전동기의 내역은 표 1에 나타내었다.

그림 1에 보인 것처럼 테스트 전동기(A)와 부하 상태를 가변할 수 있는 부하 전동기(B)를 커플링으로 직결하여 인버터(60[Hz]) 구동실험을 진행하였다. 테스트 전동기로 인입되는 전류신호는 전류 프로브 (PR 30, LEM Co.) 3개를 사용하여 3상 전류를 동시 측정하고, 내부 고정자 치(Tooth)에 부착된 자체개발 자속센서(Tooth Search Coil, TSC)를 이용하여 자속변화에 의한 유기기전력을 측정하도록 구성하였다. 인버터 구동으로 인한 스위칭 노이즈의 영향으로 센서 측정신호에 노이즈가 매우 많이 혼재되어 있었다.

이러한 센서의 신호를 전동기별 20회씩 Synergy (DAQ, 최대 1Ms/s)를 사용하여 5[KS/s] 1.64[s]동안 8,192개 데이터를 컴퓨터에 저장·반복하였다. 이때, FFT에 의한 분석가능 최대주파수는 2.5[kHz]이며, 분해능은 0.61[Hz]에 해당된다. 두 센서로부터 측정된 데이터를 이용하여 최적의 특징값들을 도출하고, 부하율에 따른 특징값의 변화경향을 수식화하여 알고리즘에 반영하였다.

Table 1. Specification of the faulted induction motors.

표 1. 고장모의 유도전동기의 상세내역

고장 종류	상세 내역	
	경미	심각
로터 변형	경미	0.2mm (굽힘 각도)
	심각	0.3mm (굽힘 각도)
로터의 동적편심	경미	0.3mm (공극, 정상 : 0.5mm)
	심각	0.2mm (공극)
로터의 정적편심	경미	1개소 (m = 20g)
	심각	2개소 (m = 20g)
베어링 불량	경미	Flaking brinelling
	심각	False brinelling
회전자 바 불량	경미	1개 슬롯 불량 (정상 : 28개)
	심각	2개 슬롯 불량
고정자 턴 단락	경미	10 턴 (U 상) (정상 : 21 턴)
	심각	5 턴 (U 상)




Fig. 1. Measurement system of signals from induction motor.  
그림 1. 유도 전동기 신호 측정 시스템

## 2.2 머신러닝 알고리즘 구성 및 동작

그림 2는 본 연구에서의 머신러닝 알고리즘의 개략도를 나타낸 것으로서, 훈련 및 테스트 과정으로 구성되어 있다. 훈련과정은 취득된 신호들로부터 여러가지 원하는 특징들을 계산하고, 계산된 특징을 정규화시킨 후 KPCA(Kernel Principal Components Analysis) 특징 축소기법에 의해 3차원 공간으로 투영하여 클러스터 군을 형성시키도록 구성하였다. 그리고, 도출된 특징값들은 부하율 변화에 따라서 자동적으로 반영되도록 커브피팅 기법을 이용하여 수식화 하였다.

테스트 과정은 훈련과정과 동일하게 새로 추출된 신호의 특징계산, 부하율 반영, 정규화 과정을 거치고, KPCA기법에 의하여 3차원 공간으로 투영되고, 특징공간에 있어서 기존 훈련데이터와의 거리를 계산하여 고장 유형을 판단하도록 하였다.

KPCA 특징추출기법은 비선형 접근방법인 Kernel 함수를 이용한 선형 PCA(Principle Component Analysis)를 사용하는 방법으로서, 입력벡터를 고차원 특징공간으로 사상시키고 이렇게 사상된 벡터들을 PCA에 의해 선형적으로 계산하는 방법을 의미한다. 즉, 원래의 입력벡터와 최종적으로 계산된 벡터사이에는 비선형 관계가 있음을 나타낸다. 입력 벡터인 특징  $x_j$ 를 고차원  $\psi(x_j)$  특징 공간으로 사상시키고,  $\psi(x_j)$ 에 대해 선형 PCA를 실시하는 기법이다. 특징들의 고유치 문제를 계산함에 의하여 고유벡터들의 주요한 요소들을 3차원  $\psi(x_j)$  특징 공간으로 사상시켜 크기순으로 나열하고, 고유치에 따른 주성분들이 클러스터 군으로 형성되도록 한다.

마지막 단계의 최종 판단방법에는 머신러닝 기법에서 주로 사용되는 k-NN(k-Nearest neighbors) Classification, SVM(Support Vector Machine),

LDA(Linear Discriminant Analysis), RFA(Random Forests Algorithm), BN(Baysian belief Network) 등 여러가지 분류기법들이 알려져 있지만, 본 연구에 있어서는 k-NN 분류기법을 적용·평가하였다.

k-NN 분류기법은 특징공간에 있어서 훈련 데이터 특징에 가장 근접한 테스트 특징을 분류하기 위한 패턴 인식법을 의미한다. 훈련 데이터의 특징들을 다차원 특징 공간에 고장유형 및 부하율에 따라 여러 영역으로 분포되도록 구성하고, 새로운 테스트 데이터의 특징이 다차원 공간상에서 클러스터 군 내의 훈련 특징들과 k번째 이내로 가장 근접한 영역의 클래스로 소속시키게 된다. 일반적으로 k값이 클수록 노이즈의 영향을 줄일 수 있지만 클래스간의 거리가 짧아지는 단점이 있으므로, 본 연구에서는 k = 3으로 설정하여 진행되었다.

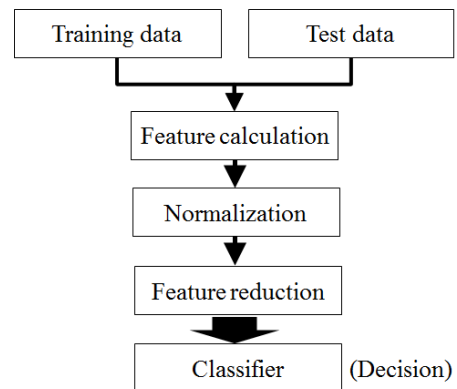


Fig. 2. Schematic diagram of the developed machine learning algorithm.

그림 2. 개발한 머신러닝 알고리즘 흐름도


## 2.3 특징 계산 (Feature calculation)

센서로부터 측정된 시계열 데이터들을 알고리즘에 적용하기 위해서는 정상 및 결함 종류에 따라서 전동기의 상태를 최적으로 반영할 수 있는 특징값 도출이 매우 중요하다.


우선, 시계열 데이터의 실효치, 피크-피크, 최대값, 최소값, 평균값, Shape factor, Skewness, Kurtosis, Crest factor, Entropy, Entropy Estimation, Lower and Upper bound of Histogram, MSF, RMSF, FC(frequency center), RVF, 주파수의 크기 및 면적(1~4kHz), AR(Auto-regression, 회귀분석) 등 다양한 값들과 주파수 변환(Fast Fourier Transform, FFT)을 통한 기본파 및 고조파의 분포를 조사하여 최적의 특징을 도출하였다. 이때 측정 신호의 데이

타 개수(측정시간) 및 샘플링 크기에 따라서 주파수 변환 결과가 발산되는 오류를 방지하기 위해서 윈도우(Hanning window)를 적용한 후 진행하였다.


그림 3은 정상전동기의 전류파형 및 고조파 측대역 사이드밴드의 위치 및 크기변화를 나타낸 그래프로써, 그림 3(a)(b)에서 인버터 구동에 의해 3상 모든 전류신호에 고조파 성분들이 혼재되어 있음을 알 수 있다. 그림 3(b)에서와 같이 부하율을 증가시키에 따라서 피크 부분이 2중 피크로 변화되는




(a) 무부하시 3상 전류파형



(b) 부하율에 따른 3상 전류파형의 변화



(c) 부하율 변화에 따른 제7차 고조파 부근의 변화




(d) 부하율에 따른 고조파 사이드 밴드의 주파수 차이변화에 대한 선형성

Fig. 3. Current waveform and variation of harmonics sideband components in normal state motor.

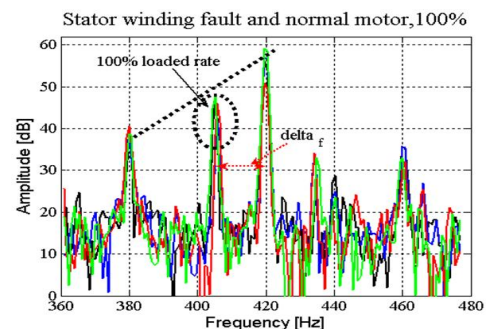
그림 3 정상전동기의 전류파형 및 고조파 사이드밴드 성분의 변화

것은 새로운 고조파 성분이 존재함을 의미하며, 100% 부하율인 경우는 그 크기도 증가됨을 알 수 있다. 이를 주파수 분석한 결과, 기본파에 대해서는 거의 유사한 크기를 보였지만, 그림 3(c)에서와 같이 제7차 고조파 저주파부근으로 측대역 사이드 밴드가 발생됨을 보였다. 이러한 경향은 제7차고조파 이외에도 제11차, 13차, 15차 고조파에서도 동일하게 발생되었다.

특히, 제7차 고조파 중심으로부터 사이드밴드까지의 주파수의 차이가 부하율 증가에 따라서 측대역 주파수의 크기가 상대적으로 높아 파악이 용이하였다. 정상전동기 및 6가지 결함의 경미, 심각한 상태의 전동기 종류에 관계없이 부하율에 따라서 항상 일정하게 사이드밴드가 발생되었으며, 이를 그림 3(d)에서와 같이 측대역 사이드밴드의 주파수 차이의 크기를 이용하면 전동기 운전 중 부하율을 파악하는 것이 가능함을 알 수 있었다. 하지만, 고장 종류에 따라서 사이드 밴드의 크기가 차이를 보였으므로, 적절하다고 판단되는 전원주파수의 0.3 배 이상인 경우에 한하여 측대역 사이드 밴드로 확정하여 부하율을 산출하도록 코딩하였다.



(a) 100% 부하시 고정자권선 결함과 정상전동기의 전류파형의 비교



(b) 100% 부하시 고정자권선 결함과 정상전동기의 제7차 고조파 부근의 변화

Fig. 4. Characteristics comparison between the stator winding faulted motor and normal state motor.


그림 4. 고정자 권선 결함과 정상전동기의 특성비교

그림 4는 고정자 권선 불량(심각상태)인 경우와 정상전동기의 전류를 비교한 것으로서, 고정자 권선 불량인 s상 전류의 크기가 다른 두 상 전류에 비해 크며, 각 상의 전류파형의 왜곡이 상이함을 알 수 있다. 이러한 특성이 그림 4(b) 제7차 고조파 부근의 주파수 분석에 있어서, 그림 내 점선(직선)으로 표기된 것처럼 각 사이드 밴드의 크기가 선형적으로 감소됨을 알 수 있다. 이를 이용하면 고정자 권선결함을 쉽게 파악하는 것이 가능할 것으로 예측된다. 또한, 원형 점선 부분은 제7차 고조파인 420[Hz]에서 저주파쪽으로 15[Hz]만큼 떨어져 있으므로 100%의 부하율로 동작됨을 알 수 있으며, 각각의 사이드밴드 주파수의 크기가 선형적으로 감소됨을 알 수 있다. 하지만 선형적 감소의 크기는 고장유형에 따라 상이함을 보였다.


일부 논문에서는 전원주파수(기본파) 측대역 성분 중 저주파측 성분은 회전자의 손상과 관련되고 고주파측 성분은 회전자 표면의 기자력(Magneto-Motive Force, MMF)과 관련되며, 이들 두 값의 크기는 차이가 있음을 설명하였다. 특히 저주파측 성분 크기와 전원주파수 크기와의 비율을 이용하여 회전자 바 손상 개수를 판단하는 기준으로 사용 가능하며, 30~50[dB]의 차이가 발생한 경우를 회전자 바 손상으로 여기고 50[dB]이상인 경우는 정상으로 판단하고 있다[1,5-6]. 하지만, 인버터로 구동한 경우에는 전류신호에 있어서 이러한 기본파의 측대역 성분들이 발생되지 않았으므로, 제7차 고조파의 측대역 성분을 활용하였다.

그림 5는 부하율 100%에서의 자속센서 출력특성 및 고장유형에 따른 주파수 분석 결과를 보인 것으로서, 그림 5(a)(b) 시계열 신호에 있어서는 인버터 구동에 따른 수많은 펄스성 신호들이 구형파 및 여러 신호들로 혼재된 상태로 측정됨을 알 수 있다. 이처럼 시계열 신호로는 타 고장상태를 판별하기 매우 어려운 상태로 보이며, 그림 5(c)기본파에 있어서도 고장유형에 따라 차이가 나타나지 않지만, 그림 5(d)의 제7차고조파의 측대역 밴드 주파수 크기(원형 점선부분)는 베어링 고장을 쉽게 판별할 수 있음을 알 수 있다. 이처럼 각 고장 유형을 판별하기 위한 명확한 특징을 추출하는 것이 매우 중요하다고 볼 수 있다.


그림 6은 정상 및 고장상태를 포함한 모든 전동기(13대)에 대하여 부하율 변화에 따른 특징의 변




(a) 자속센서 출력특성의 변화



(b) 자속센서의 출력특성 확대 그림



(c)기본파 부근의 분포



(d) 제7차 고조파 대역의 베어링 불량과 정상전동기의 주파수 분석결과 비교

Fig. 5. Analysis of the frequency domain about signals of the magnetic flux sensor according to the faulted types.

그림 5. 자속센서의 출력특성 및 고장유형에 따른 주파수 특성 분석

화를 보였다. 그림 6(a)~(c)는 전류신호(Ir)에 대한 실효치, 정상분, 제7차 고조파 측대역 밴드의 주파수 차이에 대한 변화를 보였고, 그림 6(c)~(f)는 자

속센서에 대한 실효치, 제3차 고조파 크기, 제7차 고조파 측대역 밴드의 주파수 차이에 대한 변화를 보였다. 그림 6(a)에서 각 결함들이 부하율 증가에 따라서 증가됨을 알 수 있으며, 무부하(0%)에서 고정자 권선 결함(stator winding faults)이 타 전동기에 비하여 값이 낮지만, 그림 6(b)에서와 같이 3상 전류크기에 대한 정상분 크기에 있어서는 타 신호에 비해 높음을 알 수 있다. 이처럼 단상에 대한 크기 변화도 중요하지만, 3상을 동시에 비교함에 의하여 결함종류에 따른 특징 값의 변화를 파악하는 것이 중요하다고 볼 수 있다. 전류신호 제7차고조파와 측대역 성분과의 주파수 차이를 나타낸 그림 6(c)에 있어서는 각 결함별 거의 비슷한 양상을 보이지만, 부하율 증가에 따라 그 크기가 증가됨을 알 수 있다.

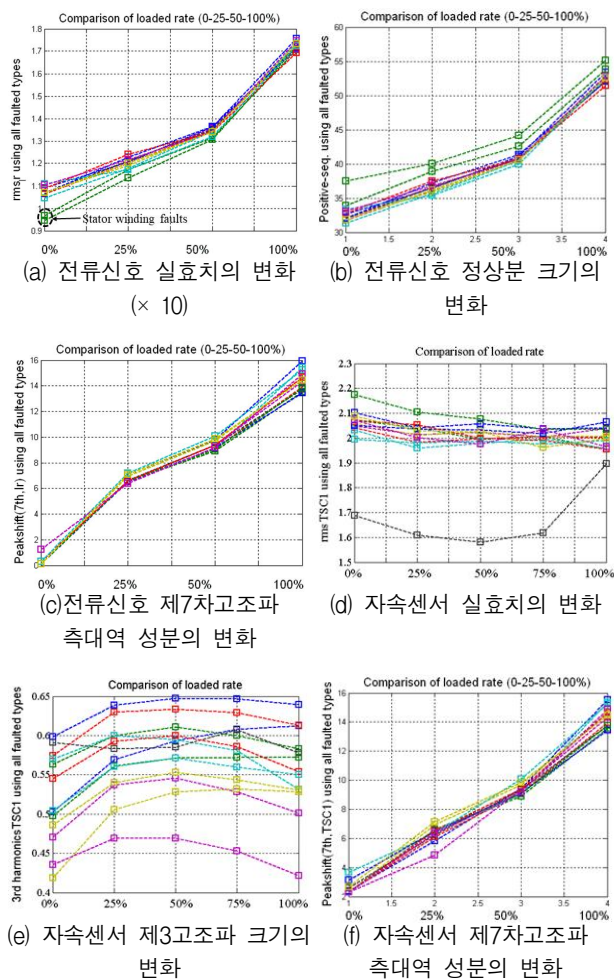


Fig. 6. Features variation on the load rate according to simulated induction motors using current signal and the magnetic flux sensor.


그림 6. 전류신호(I<sub>r</sub>) 및 자속센서에 대한 특징들의 모의 전동기 종류별 부하율 변화

또한, 그림 6(d)는 자속센서의 실효치 변화를 나타낸 것으로서, 동적편심(Rotor Dynamic Eccentricity) 전동기 이외에는 부하율에 따라 거의 일정한 값을 나타냄을 알 수 있다. 하지만, 제3고조파 크기 변화를 나타낸 그림 6(e)에서는 동일 부하율에서 결함 전동기에 따라서 크기의 큰 변화를 보이며, 부하율 변화에 따라서 그 크기가 일정함을 알 수 있다. 이러한 분포를 통하여 부하율을 정확히 파악한 경우에는 결함 전동기의 종류를 쉽게 파악할 수 있다.

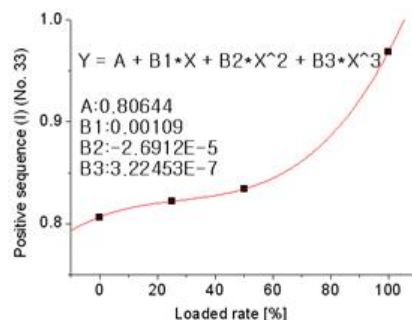
그림 6(f)는 자속센서의 제7차고조파와 측대역 성분과의 주파수 차이를 나타낸 것으로서, 전류센서와 유사하게 각 결함별 거의 비슷한 크기를 보이며 부하율에 따라 그 크기가 증가됨을 알 수 있다.

따라서, 전동기 결함 종류에 따른 특징을 계산하기 위하여 전류신호는 3상 모두에 대하여 실효치, 피크-피크, 고조파 성분의 크기, 사이드밴드의 크기 및 주파수 차이에 대한 15개 특징( $3 \times 5 = 15$ )과 3상 전류 불평형, 영상분, 정상분, 역상분 4가지 특징을 포함하여 총 19개의 특징을 추출하였으며, 자속센서인 경우는 실효, 피크-피크, 기본파 및 3, 7, 9차 고조파의 크기 및 사이드밴드의 크기에 대한 10개의 특징값을 추출하였다.


전류 및 자속센서로부터 29개의 특징을 도출하였으며, 이를 이용하여 13개 전동기에 대하여 20회씩 각 부하율에 따른 특징들을 훈련 데이터로서 알고리즘에 구성하였다.



(a) 전류신호 실효치의 부하율에 따른 커브피팅 결과 ( $\times 10$ )



(b) 전류신호 정상분 크기의 부하율에 따른 커브피팅 결과



(c) 자속센서 실효치의 부하율에 따른 커브피팅 결과

Fig. 7. urve fitting results according to load rate on current signal and magnetic flux sensor.

그림 7. 전류신호(I<sub>r</sub>) 및 자속센서에 대한 부하율에 따른 특징들의 커브피팅 결과


그림 7은 전류신호(I<sub>r</sub>) 및 자속센서에 대한 부하율 변화에 대한 임의 특징들의 커브피팅 실시 예를 나타낸 것으로서, 운전 조건에 따라 부하율이 변화 되더라도 각 특징별로 부하율에 따른 특징 값이 자동으로 계산하도록 코딩되어 있다. 이렇게 도출된 특징값들은 각 결합별로 그림 8에서와 같이 자동으로 정규화 과정을 거치도록 구성하였다.

그림 8은 본 알고리즘에 있어서 고장종류 판단 정확도를 향상시키기 위한 정규화기법 실시 전·후의 특징들의 분포 변화를 나타낸 것으로서, 각 결합 전동기의 종류에 따라 분포가 명확히 차이가 있음을 알 수 있다.


정규화는 전동기로부터 측정된 모든 신호의 임의 특징값에 대하여 각 전동기별 평균치를 계산하고, 계산된 평균치로 해당 전동기의 20회 측정된 특징 값을 나누고, 전동기 종류별 평균치 크기 순서(rank)를 파악하여 1/13개 크기의 가중치를 곱하였다. 이렇게 도출된 최종값 중에서 최대치를 이용하여 동일 특징값들을 나누어 정규화시키도록 구성하였다. 이렇게 함으로서 결합 종류별 특징 분포를 명확히 할 수 있었다.

마지막으로, 결합 전동기 종류별로 5회 측정된 테스트 신호들을 본 알고리즘에서 반영하여, 정규화, KPCA 특징 축소 기법, k-NN 판단 알고리즘에 의한 분류 정확도(Classification accuracy)를 조사한 결과, 약 84.6%의 분류 정확도를 보였다.

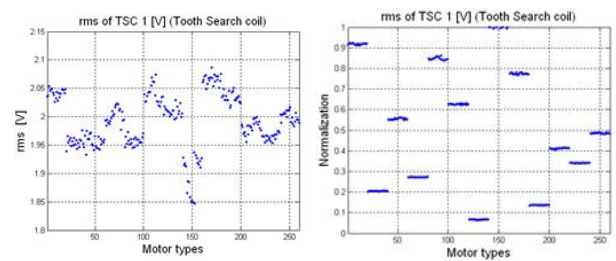
주로 정적편심(Mass unbalance) 전동기에 대하여 고장정도(경, 중) 사이의 판단오류, 회전자 손상(Broken rotor bar)과 회전자 변형(Bowed rotor)사이의 판단오류가 발생되었다.



(a) 정규화 전(좌측, ×10) 및 후(우측)의 전류신호 실효치의 변화



(b) 정규화 전(좌측) 및 후(우측)의 전류신호 정상분 크기의 변화



(c) 정규화 전(좌측) 및 후(우측)의 자속센서 실효치의 변화

Fig. 8 Feature comparison by the normalization process on the current and flux sensor signals from 13 motors (loaded rate 0%, 1-20 : M10(Bearing fault II), 21-40 : M12(Broken rotor bar II), 41-60 : M14(Stator fault II), 61-80 : M1(normal motor), 81-100 : M4 (bowed rotor bar II), 101-120 : M6 (Misalignment II) 121-140 : M8 (Mass unbalance III)).

그림 8. 전류신호(I<sub>r</sub>) 및 자속센서에 대한 특징들의 전동기 종류별 정규화 이전 및 이후의 분포 비교 (무부하시로서 부하율 0%, 1-20 : M10(Bearing fault II), 21-40 : M12(Broken rotor bar II), 41-60 : M14(Stator fault II), 61-80 : M1(normal motor), 81-100 : M4 (bowed rotor bar II), 101-120 : M6 (Misalignment II) 121-140 : M8 (Mass unbalance III))

이를 개선하여 95% 이상의 분류 정확도를 얻기 위해서는 판단오류가 발생하는 결합에 대하여 추가적인 새로운 특징 도출이 필요할 것으로 판단된다. 따라서, 향후에는 Wavelet를 이용하여 상기 결합 오류를 극복하기 위한 알고리즘 개선 연구를 진행할 계획이다.

### III. 결론

본 논문은 전류신호와 자속신호를 이용한 유도전동기 예방진단시스템을 개발하기 위한 알고리즘의 구성에 대하여 논하고, 특징계산 및 그에 따른 분류 정확도에 평가한 결과를 나타낸 것으로서, 주요한 결과는 다음과 같다.

(1) 전류신호와 자속센서를 이용하여 결함 종류를 판별하기 위한 최적 특징추출단계를 통하여 총 29개의 특징을 도출하여 높은 분류 정확도를 얻을 수 있는 유효한 특징임을 알고리즘을 통해 판단하였음.

(2) 전류신호의 제7차 고조파 중심으로부터 사이드밴드까지의 주파수의 차이가 부하율 증가에 따라서 증가되는 경향을 이용하여 임의의 부하율 상태를 반영할 수 있는 알고리즘을 도출하였음.

(3) 고장종류에 판단 정확도를 향상시키기 위하여 새로운 정규화기법을 도입하여 각 결함 전동기의 종류에 따라 분포가 명확하도록 구성함.

(4) KPCA 특징 축소 기법, k-NN 판단 알고리즘에 의한 분류 정확도(Classification accuracy)를 조사한 결과, 약 84.6%의 분류 정확도를 보임. 주로 정적편심의 고장정도(경, 중), 그리고 회전자 손상과 회전자 변형사이의 판단오류가 주로 발생되었음.

### References

[1] A. J. Marques Cardoso, S. M. A. Cruz, D. S. B. Fonseca, "Inter-Turn Stator Winding Fault Diagnosis in Three-phase Induction Motors, by Park's Vector Approach," *IEEE Trans. Energy Conversion*, Vol.14, No.3, pp.595-598, 1999. DOI: 10.1109/IEMDC.1997.604083

[2] Andreas Stavrou, Howard G. Sedding, and James Penman, "Current Monitoring for Detecting Inter-Turn Short Circuits in Induction Motors," *IEEE Trans. Energy Conversion*, Vol.16, No.1, pp.32-37, 2001. DOI: 10.1109/60.911400

[3] W. T. Thomson, Derek Morrison, "On-line diagnosis of stator shorted turns in Mains and inverter fed low voltage induction motors," *Int. Conf. on Power electronics, Machines and Drives*,

No.2, pp.122-127, 2002. DOI: 10.1049/cp : 20020100

[4] Behrooz Mirafzal, Nabeel. A. O. Demerdash, "On Innovative Methods of Induction Motor Inter-Turn and Broken-Bar Fault Diagnostics," *IEEE Int. Con. on Electric Machines and Drives*, pp.762-769, 2005. DOI: 10.1109/IEMDC.2005.195808

[5] Xianghui Huang, Thomas G. Habetler, and Ronald G. Harley, "Detection of Rotor Eccentricity Faults in a Closed-Loop Drive-Connected Induction Motor Using an Artificial Neural Network," *IEEE Trans. Power Electr.*, Vol.22, No.4, pp. 1552-1559, 2007. DOI: 10.1109/TPEL.2007.900607

[6] J. Martinez, A. Belahcen, A. Muetze, "Analysis of the vibration magnitude of an induction motor with different numbers of broken bars," *IEEE Trans. Industry Appl.*, Vol. 53, pp.2711-2720 2017. DOI: 10.1109/TIA.2017.2657478

[7] H. Merabet, T. Bahi, D. Drici, N. Halam, K. Bedoud, "Diagnosis of rotor fault using neuro-fuzzy inference system," *J. Fundam. Appl. Sci.* Vol. 9, pp.170 - 182, 2017. DOI: 10.4314/jfas.v9i1.12

[8] Jordi Burriel-Valencia et al., "Automatic Fault Diagnostic System for Induction Motors under Transient Regime Optimized with Expert Systems," *Electronics*, Vol.8, No.6, pp.1-16, 2019. DOI: 10.3390/electronics8010006

[9] Levent Eren, and Michael J. Devaney, "Bearing Damage Detection via Wavelet Packet Decomposition of the Stator Current," *IEEE Trans. Instru. and Mea.*, Vol.53, No.2, pp.431-436, 2004. DOI: 10.1109/TIM.2004.823323

[10] Gojko Joksimovic, Jim Penman, "The Detection of Interturn Short Circuits in the Stator Windings of Operating Motors," *IEEE Trans Ind. Electr.*, Vol.47, No.5, pp.1078-1084, 2000. DOI: 10.1109/41.873216

[11] S. M. A. Cruz, A. J. M. Cardoso, H. A. Toliyat, "Diagnosis of Stator, Rotor and Airgap Eccentricity Faults in Three-Phase Induction Motors Based on the Multiple Reference Frames Theory," *38st IAS Ann. Meet.*, pp.1340-1346,



2003. DOI: 10.1109/IAS.2003.1257725

[12] Humberto Henao, Cristian Demian, and Gerard-Andre Capolino, "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.

DOI: 10.1109/IAS.2002.1043735

[13] A. Muetze, A. Binder, H. Vogel, J. Hering, "Experimental Evaluation of the Endangerment of Ball Bearings due to Inverter-Induced Bearing Currents," *IEEE Ind. Appl. Conf., 39th IAS Annual Meeting*, pp.1989-1995, 2004.

DOI: 10.1109/IAS.2004.1348741

[14] Jose L. H. Silva, A. J. Marques Cardoso, "Bearing Failures Diagnosis in Three-Phase Induction Motors by Extended Park's Vector Approach," *31st Ann. Conf. IEEE Ind. Electr. Soc.*, pp. 2591-2596, 2005.

DOI: 10.1109/IECON.2005.1569315

[15] Homayoun Meshgin Kelk, Alireza Eghbali, Hamid A. Toliyat, "Modeling and Analysis of Cage Induction Motors under Rotor Misalignment and Air Gap Eccentricity," *Indus. Appl. Conf.*, pp. 1324-1328, 2005. DOI: 10.1109/IAS.2005.1518531

[16] A. Jornet, J. Cusido, "Double Frequency Test for Detecting Faults in Induction Machines," *31st Ann. Conf. IEEE Ind. Electr. Soc.*, pp.1516-1521, 2005.

DOI: 10.1109/IECON.2005.1569129

[17] M'hamed Drif, A. J. Marques Cardoso, "Airgap Eccentricity Fault Diagnosis, in Three-Phase Induction Motors, by the Complex Apparent Power Signature Analysis," *IEEE Trans. Ind. Electr.*, Vol.55, No.3, pp.1404-1410, 2008. DOI: 10.1109/SPEEDAM.2006.1649745

[18] Xiaodong Li, Qing Wu, and Subhasis Nandi, "Performance Analysis of a Three-Phase Induction Machine With Inclined Static Eccentricity," *IEEE Trans. Ind. Appl.*, Vol.43, No.2, pp.531-541, 2007.

DOI: 10.1109/TIA.2006.889806

## BIOGRAPHY

### Sang-Bo Han (Member)



1998 : BS degree in Electrical

Engineering, Kyungnam University.

2000 : MS degree in Electrical

Engineering, Kyungnam University.

2004 : PhD degree in Electronic

Engineering, University of Tokyo.

2015.2~2016.2 : Visiting scholar,

University of California at San Diego,

USA