

음향 방출 신호와 질감 분석을 이용한 유도전동기의 베어링 복합 결함 검출

장 원 철*, 김 종 먼*

Bearing Multi-Faults Detection of an Induction Motor using Acoustic Emission Signals and Texture Analysis

Won-Chul Jang*, Jong-Myon Kim*

요 약

본 논문에서는 유도 전동기 결함 중 가장 많은 비중을 차지하는 베어링의 복합 결함을 검출하기 위해 음향 방출 신호와 이를 영상화하여 질감 분석을 이용한 결함 검출 방법을 제안한다. 영상화된 결함 신호가 갖는 엔트로피, 픽셀의 동질성 및 에너지 특징을 분석하고, 그레이-레벨 동시발생 행렬을 통해 영상의 에너지, 동질성 및 다양성의 세 가지 질감 특징을 추출한다. 추출된 세 가지 질감 특징을 퍼지-ARTMAP(Fuzzy-ARTMAP)의 입력으로 사용하여 베어링의 외륜-내륜, 내륜-롤러 및 외륜-롤러에 대한 복합 결함을 분류한다. 총 10회에 걸쳐 제안한 방법의 분류 성능을 평가한 결과, 100%의 분류 정확성을 보였다.

▶ Keywords : 복합 결함 검출, 유도 전동기, 음향 방출 신호, 그레이레벨 동시발생 행렬, 질감 분석, 퍼지-ARTMAP

Abstract

This paper proposes a fault detection method utilizing converted images of acoustic emission signals and texture analysis for identifying bearing's multi-faults which frequently occur in an induction motor. The proposed method analyzes three texture features from the converted images of multi-faults: multi-faults image's entropy, homogeneity, and energy. These extracted features are then used as inputs of a fuzzy-ARTMAP to identify each multi-fault including outer-inner, inner-roller, and outer-roller. The experimental results using ten times trials indicate that the proposed method achieves 100% accuracy in the fault classification.

▶ Keywords : Multi-fault detection, induction motor, acoustic emission signals, gray-level co-occurrence matrix, texture analysis, fuzzy ARTMAP

•제1저자 : 장원철•교신저자 : 김종면

•투고일 : 2014. 2. 18, 심사일 : 2014. 3. 11, 게재확정일 : 2014. 3. 27.

* 울산대학교 전기전자컴퓨터공학과(School of Electrical and Computer Engineering, University of Ulsan)

※ 이 논문은 정부(교육부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것임 (NRF-2012R1A1A2043644).

I. 서론

유도 전동기는 산업 현장 전반에 사용되는 주요한 장비로서 견고한 내구성과 단순 구조로 구성되어 있다. 생산 공정 자동화와 장비의 대용량 고효율화로 유도 전동기 결합에 의해 발생하는 생산성 저하와 유지보수 비용, 장비 교체 등의 경제적 손실을 최소화하기 위해 유도 전동기의 관리 및 유지보수의 중요성이 증대되고 있다.[1-3]

유도 전동기의 결합 중 가장 많은 비중을 차지하는 것은 베어링 관련 결합으로, 해당 결합을 사전에 예지하고 적절한 시기에 정비하지 못할 경우 다른 결합도 야기할 수 있는 문제점을 가지고 있다. 따라서 최근에는 베어링 결합을 조기에 예지하기 위한 연구가 활발히 진행되고 있다.[4-8]

기존 연구에서는 진동 및 전류 신호를 취득하여 STFT(Short Time Fourier Transform)이나 웨이블릿 패킷 변환(Wavelet Packet Transform), EMD(Empirical Mode Decomposition) 등의 신호 처리 기법들을 사용하여 주파수 영역에서 베어링 결합의 특징 주파수를 표현하는 구간을 선택하는 방법이 제안되었으나, 신호의 비정상(non-stationary)적 특징으로 결합 신호를 포함하는 주파수 분해 단계나 구간 선택에 대한 기준을 규정할 수 없는 문제점을 가지고 있다. 또한 베어링 결합은 크게 단일 결합과 복합 결합 두 가지 유형으로 분류되는데, 베어링의 구조적인 요인과 신호를 취득하는 센서 설치의 위치적 제약으로 복합 결합은 특정 결합의 특징이나 정도가 매우 미비하게 나타날 수 있다.

따라서 기존 연구에서 사용된 진동 및 전류 신호 대신에 잡음에 약하지만 미세한 결합에도 결합의 고유한 신호적 특징이 잘 반영되는 음향 방출(Acoustic Emission)신호를 영상화하고, 영상화된 신호에서 나타나는 질감 특징들을 공간적으로 분석하여 전술한 신호 분해 단계 및 구간 선택의 문제점들을 극복하고자 한다.

영상의 질감 분석을 위해 사용되는 기법 중 하나인 GLCM(Gray Level Co-occurrence Matrix)은 픽셀 정보의 관계를 공동발생 행렬로 나타내어 영상이 갖는 공간적인 특징을 통계적으로 분석하는 방법이다. 영상이 갖는 픽셀 값의 구성, 대비, 질감의 동질성, 다양성 등이 영상에 얼마나 포함되어 있는지를 나타내어 영상을 분류하는데 효과적이다.

본 논문에서는 음향 방출 신호를 2차원의 회색조 영상으로 변환하고 GLCM을 적용하여 영상의 에너지(Energy), 동질성(Homogeneity) 및 영상이 포함한 정보의 다양성(Entropy)을 특징으로 추출한다. 추출된 세 가지 특징 정보

를 퍼지-ARTMAP(Fuzzy-ARTMAP)의 입력으로 사용하여 베어링의 외륜-내륜, 내륜-물러 및 외륜-물러에 대한 복합 결합을 분류한다. 각 결합 신호는 초당 1 MHz로 샘플링되어 0.05초 단위로 나누어 500개로 구성되어 있으며, 이 중 50개의 음향 신호는 분류기의 기계 학습에 사용하였고 나머지 450개를 제안한 알고리즘의 성능 검증을 위한 테스트 데이터로 사용한다.

본 논문의 구성은 다음과 같다. 2장에서는 제안하는 결합 검출 시스템에 대해 설명하고, 3장에서는 베어링의 복합 결합 및 이를 영상화된 신호에 대해 분석한다. 4장에서는 영상화 신호에서 추출한 특징을 퍼지-ARTMAP의 입력으로 사용하여 베어링 복합 결합의 분류 성능 결과를 분석한다. 마지막으로 5장에서는 본 논문의 결론을 맺는다.

II. 제안하는 복합 결합 검출 시스템

그림 1은 본 연구에서 제안하는 베어링 복합 결합 검출 시스템의 흐름도를 보여준다. 입력된 음향 신호는 이산 웨이블릿 변환 과정을 거쳐 회색조 영상으로 변환되고, GLCM을 이용하여 영상화된 음향 신호의 공간적 특징을 추출한다.

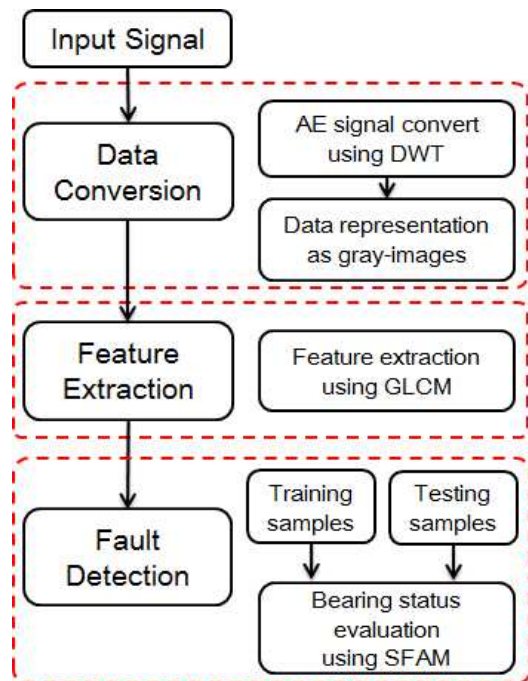


그림 1. 복합 결합 시스템 구조
Fig. 1. System architecture of multiple faults

그림 2는 본 논문에서 베어링의 복합 결함 검출 및 분류 실험을 위해 사용된 베어링 부품의 결함을 보여준다. 본 실험에서는 베어링의 내륜, 외륜 및 롤러에 각각 너비 0.6mm, 길이 6mm의 인위적인 결함을 만들어 내륜-외륜 (Inner-Outer), 내륜-롤러 (Inner-Roller Fault) 및 외륜-롤러 (Outer-Roller)의 세 가지 복합 결함을 대상으로 취득한 음향 신호를 사용하였다.




그림 2. 베어링 결함 정보
Fig. 2. Information of bearing faults

1. 음향 신호의 영상화

본 논문에서는 입력된 1차원 음향 신호를 2차원 회색조 영상으로 변환하는 단계를 거친다. 그림 3은 영상화된 음향 신호의 예를 보여준다. 영상의 크기는 신호의 샘플링 데이터의 웨이블릿 변환 결과에 따라 정사각형 크기로 생성된다. 본 논문에서 사용된 음향 신호의 크기는 256단계로 정규화되며, 정규화된 신호는 158*158 크기의 영상으로 변환되어 특징 추출을 위해 사용된다.




그림 3. 음향 신호의 2차원 영상화
Fig. 3. Conversion of acoustic signal to 2D image

2. 특징 추출

GLCM을 사용하여 256단계로 정규화된 회색조 영상을 대상으로 특징을 추출한다. GLCM은 영상의 픽셀값으로 공동발생 행렬을 생성하여 기준 픽셀에서 인접한 픽셀간의 관계를 통계적으로 분석하는 영상 분석 기법이다. [10] 그림 4는 입력된 영상으로 공동발생 행렬을 생성하는 예를 보여준다. 기준 픽셀(reference pixel)의 값은 x , 이웃하는 픽셀(neighbour pixel)의 값은 y 좌표가 되어 행렬의 (x, y) 위

치에 반영되며, 동일한 픽셀 관계가 많을수록 해당좌표에서 반영되는 값도 증가한다.




그림 4. 공동발생 행렬의 생성 예
Fig. 4. An example of co-occurrence matrix

그림 5는 기준 픽셀이 참조 방향에 대한 예를 나타낸다. 영상의 질감 분석은 기준 픽셀에서 참조하는 방향(0°, 45°, 90°, 135°)에 따라 반영되는 특징 결과가 달라질 수 있으므로 결함 신호의 특징을 가장 잘 반영하는 참조 픽셀의 방향과 거리 선택이 필요하다.




그림 5. 픽셀 참조 방향
Fig. 5. Direction of a reference pixel

본 논문에서는 결함 유형을 분류하기 위한 근거로 영상의 에너지(Energy), 구성된 픽셀의 동질성(Homogeneity) 및 영상에 포함된 정보의 다양성(Entropy)을 특징으로 추출하여 영상이 갖는 공간적 특징을 분석하였다. 각 특징의 표현은 식 (1)을 따른다. P_{ij} 는 정규화된 행렬 값을 나타내며, a_{ij} 는 행렬의 각 요소를, i, j 는 공동 발생 행렬의 위치를 나타낸다.

$$\begin{aligned}
 Energy &= \sum_{i,j=0}^{n-1} (P_{i,j})^2 \\
 Entropy &= \sum_{i,j=0}^{n-1} P_{i,j} (-\ln P_{i,j}) \\
 Homogeneity &= \sum_{i,j=0}^{n-1} \frac{P_{i,j}}{1 + (i-j)^2}
 \end{aligned} \tag{1}$$

$$P_{ij} = \frac{a_{ij}}{a_{11} + a_{12} + \dots + a_{n-1n-1}}$$

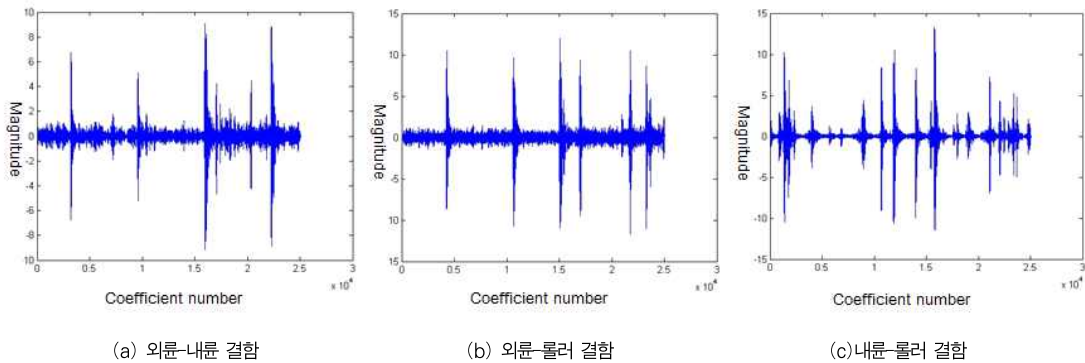


그림 7. 복합 결함 유형별 DWT 변환
Fig. 7. DWT transformation of each multi-fault




그림 6. 복합 결함 유형별 스펙트럼
Fig. 6. Spectrum of each multi-fault


III. 베어링 결함 분석

그림 6은 초당 1MHz로 샘플링된 복합 결함 유형별 신호를 주파수 영역에서 표현한 스펙트럼의 일부를 보여준다. 그림 6에서 보느냐와 같이 베어링의 세 가지 복합 결함 스펙트럼은 주파수 영역에서 모두 유사하게 나타남에 따라 각각의 결함 특징이 주파수 영역에서 제대로 반영되지 않는 것을 알 수 있다. 반면에 그림 7에서 보느냐와 같이 동일한 데이터를 이산 웨이블릿 변환한 결과는 주파수 영역에서와는 달리 비교적 복합 결함의 특징이 잘 반영되어 결함 유형별로 나타내는 특징이 상이함을 알 수 있다. 그러나 이산 웨이블릿 변환을 사용하여 결함 신호에 대한 모델링을 수행하는 경우 결함 특징이 나타나는 노드를 선택해야 하는 문제점을 가지고 있다. 이는 유도 전동기의 동작 회전수가 항상 같은 회전수의 동작을 보장하지 않기 때문에 결함의 특징 또한 항상 일정 주기

다 발생되지 않기 때문이다. 따라서 본 논문에서는 전술한 노드 선택의 문제점을 극복하기 위해 1차원 음향 신호를 2차원으로 재구성하여, 신호의 특징을 공간적인 측면에서 분석하고자 한다.

신호 분해를 통한 노드 선택과 포락선 모델링은 결함의 특징 발생 주기가 일정하지 않는 경우 발생 주기 오차에 대한 추가적인 모델링이나 오차 범위에 대한 신호 분해가 요구되지만, 신호를 영상화하면 결함의 특징 발생 주기가 다소 일정하지 않더라도 영상 내에서는 일정한 패턴으로 나타나게 된다. 일정한 패턴으로 이뤄진 신호를 공간적으로 분석하게 되면 각 영상에 나타나는 신호 발생 주기나 간격에 대한 오차가 생길더라도 추가적인 모델링이나 분석 기법이 요구되지 않는 장점이 있다.

그림 8은 베어링 복합 결함의 음향 신호를 영상화한 결과를 보여준다. 취득된 신호의 크기 차이나 전체적인 신호 경향이 영상에서 결함 유형별로 다르게 나타나고 있음을 알 수 있다.



(a) 외륜-내륜 결함 (b) 외륜-롤러 결함 (c) 내륜-롤러 결함
 그림 8. 복합 결함 신호의 영상화

Fig. 8. Converted images of multi-fault signals

그림 8에서 내륜-롤러 결함의 경우 다른 두 결함 유형과 비교하여 영상에 표현되는 무늬의 전체적인 선명도가 낮고 발생 빈도가 높은 것을 보여준다. 그림 9의 영상 결과를 보면 내륜-롤러 결함은 외륜-내륜 및 외륜-롤러 결함과 비교하여 위상차이가 적은 신호가 높은 빈도로 발생하는 것을 알 수 있다.





그림 9. 내륜-롤러 신호의 영상화

Fig. 9. Converted images of inner-roller fault signals

외륜-내륜 결함과 외륜 롤러 결함은 그림 10에서 표시된 부분과 같이 꺾쇠무늬의 선명도에서 차이가 나는 것을 확인할 수 있다. 표시된 부분에서 외륜-내륜 결함의 영상이 갖는 꺾쇠무늬가 외륜-롤러 결함에 비해 선명도가 균일 하지 못하며, 가로 무늬의 발생 빈도도 낮다.




(a) 외륜-내륜 결함 (b) 외륜-롤러 결함


그림 10. 외륜-내륜과 외륜-롤러 영상의 차이

Fig. 10. Difference between outer-inner and outer-roller images

또한 그림 11에서 보는바와 같이 외륜-롤러 결함의 영상이 외륜-내륜 결함 영상보다 전체적으로 밝기가 높은 것을 알 수 있다. 더불어 그림 11 (b)에서 외륜-롤러 결함 신호가 전체적으로 위상 크기가 큰 신호들이 포함되어 있음을 알 수 있다.



(a) 외륜-내륜 결함



(b) 외륜-롤러 결함

그림 11. 외륜 복합 결함 신호의 영상화

Fig. 11. Converted images of outer multi-fault signals

각 유형별 결함 신호에서 나타내는 무늬의 선명도와 발생 빈도가 다르므로 이들 영상에서 질감 특징을 추출하여 이용하여 베어링의 복합 결함 분류에 사용할 수 있다. 본 논문에서는 영상이 포함하는 정보의 다양성(Entropy), 영상의 에너지(Energy) 및 구성된 픽셀의 동질성(Homogeneity)을 추출하여 결함 유형을 분류한다. 그림 12는 500개로 구성된 데이터 셋을 사용하여, GLCM에서 참조 가능한 방향별로 기준 픽셀에서 4픽셀 떨어진 참조 픽셀의 관계로 구성된 공동발생 행렬로 추출한 세 가지 특징의 분포를 보여준다. 세 가지 유형의 베어링 복합 결함 신호에서 추출한 특징들을 3차원 공간에 분포 시켰을 때 그림 12 (a)와 같이 동일 유형 신호끼리 군집해있는 0° 방향에서 추출한 특징 결과가 결함 신호 유형의 특징을 일관성 있게 보여준다.

IV. 실험

표 1. 질감 특징 추출과 퍼자-ARTMAP을 이용한 결함 분류 성능
 Table 1. Fault classification performance using the texture feature extraction and Fuzzy-ARTMAP

결함 유형	외륜-내륜	외륜-롤러	내륜-롤러
외륜-내륜	100%	0%	0%
외륜-롤러	0%	100%	0%
내륜-롤러	0%	0%	100%

표 2. SIFT 기법을 이용한 결함 분류 성능
 Table 2. Fault classification performance using the SIFT

분류 결과	외륜-내륜	외륜-롤러	내륜-롤러
외륜-내륜	94.43%	5%	0.57%
외륜-롤러	0%	100%	0%
내륜-롤러	8.59%	3.68%	87.73%

초당 1 MHz로 샘플링된 결합 유형별 음향 데이터를 0.05 초 단위로 나누어 총 500개의 데이터 셋으로 구성하여 실험하였다. 이 중 50개의 데이터는 퍼지-ARTMAP의 기계학습에 사용하였고, 나머지 450개 데이터로 분류기의 분류 성능을 실험하였다. 본 논문에서 사용된 분류기인 퍼지-ARTMAP은 신경망의 한 형태로 0과 1사이의 퍼지 멤버십 값(각 특징의 정도)을 갖는 패턴에 의해서 입력을 구분하는 학습방식이다.[11]

실험은 총 10회에 걸쳐 진행하였으며, 표 1은 복합 결합 신호에 대해 제안한 방법의 분류 성능을 보여준다. 알고리즘에 입력된 데이터를 분류한 결과, 표 1에서 보논바와 같이 영상화된 음향 신호에서 추출한 특징을 이용한 퍼지-ARTMAP의 분류 성능이 매우 우수함을 알 수 있다. 표 2는 동일한 실험 환경에서 기존 알고리즘[12]의 분류 정확도를 나타낸다. 실험 결과, 제안한 알고리즘의 분류 성능이 더 우수함을 알 수 있

다. 기존의 알고리즘은 SIFT(scale invariant feature transform)기법을 적용하여, 각 결합 유형별 특징으로 키포인트 기술자(keypoint descriptor)를 추출하였다. 그러나 잡음에 예민한 음향 신호의 특성이 기존의 알고리즘에는 고려되지 않았기 때문에, 신호를 영상화하는 과정에서 생기는 데이터의 변화로 인하여 키포인트 기술자의 큰 변화를 야기하였다.

V. 결론

본 논문에서는 유도 전동기의 베어링 복합 결합 검출 방법을 제안하였다. 제안한 방법은 음향 신호에 대한 256단계 회색조 영상화를 통해 각 결합 유형의 영상이 갖는 에너지(Energy), 영상 픽셀의 동질성(Homogeneity)과 정보의 다양성(Entropy)을 특징으로 추출한다. 영상화된 데이터에서 추출된 결합의 세 가지 특징을 퍼지-ARTMAP의 입력으로

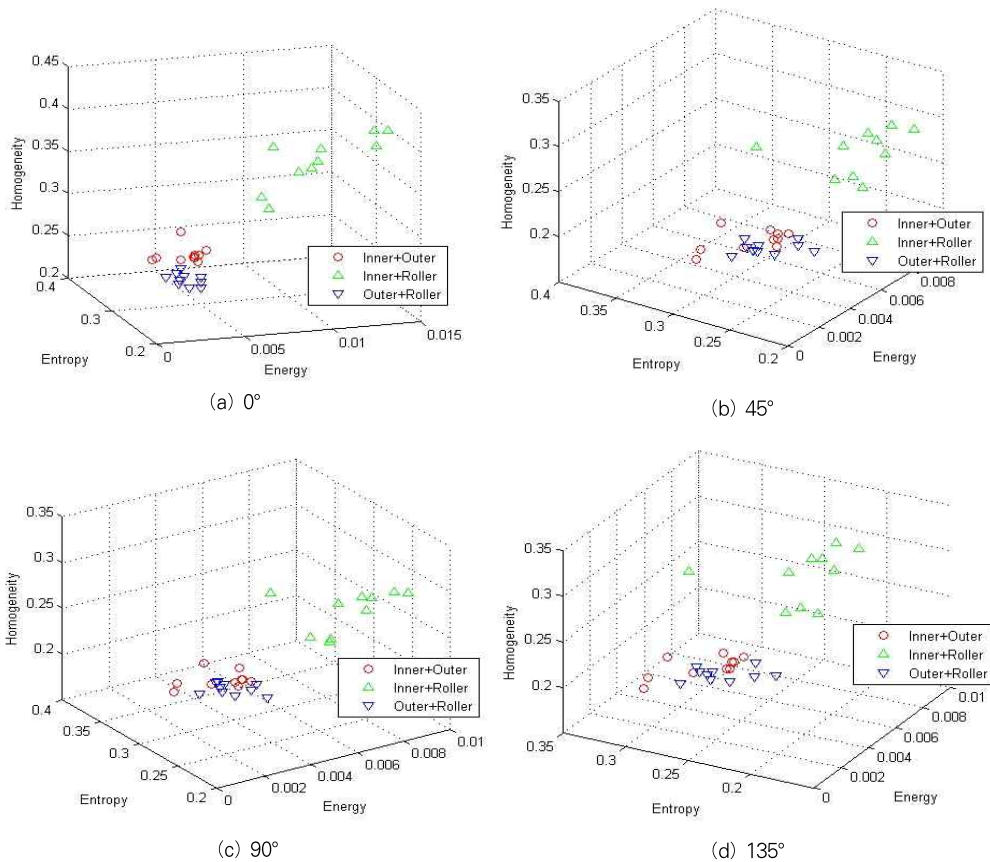


그림 12. GLCM 참조 방향별 특징 분포
 Fig. 12. Feature distribution according to the GLCM reference direction

사용하여 베어링의 복합 결함 유형을 분류하였다. 총 10회에 걸쳐 입력된 결함 데이터의 분류 성능을 실험한 결과 100%의 분류 성능을 보였다. 또한 기존의 알고리즘과 비교한 실험에서도 제안한 알고리즘의 성능이 우수한 결과를 보였다. 이러한 결과는 영상화된 음향 신호에서 추출한 질감 특징을 베어링의 복합 결함 분류 시스템에 활용 할 수 있음을 보여준다.

참고문헌

- [1] K. Shahzad, P. Cheng, and B. Oelmann, "Architecture Exploration for a High-Performance and Low-Power Wireless Vibration Analyzer", *IEEE Sensors Journal*, Vol. 13, No. 2, pp. 670-682, February 2013.
- [2] C.-H. Hwang, M. Kang, J.-M. Kim, "A Study on Robust Feature Vector Extraction for Fault Detection and Classification of Induction Motor in Noise Circumstance," *Journal of the Korea Society of Computer and Information*, Vol. 16, No. 12, pp. 187-196, 2011.
- [3] C.-H. Hwang, Y.-M. Kim, C.-H. Kim, J.-M. Kim, "Fault Detection and Diagnosis of Induction Motors using LPC and DTW Methods," *Journal of the Korea Society of Computer and Information*, Vol. 16, No. 3, pp. 141-147, 2011.
- [4] M. Deriche, "Bearing Fault Diagnosis Using Wavelet Analysis," *International Conference on Computers, Communication and Signal Processing with Special Track on Biomedical Engineering*, pp. 197-201, 2005.
- [5] W. Zhou, B. Lu, T. G. Habetler, and R. G. Harley, "Incipient Bearing Fault Detection via Motor Stator Current Noise Cancellation Using Wiener Filter", *IEEE Transactions on Industry Applications*, Vol. 45, No. 4, pp. 1309-1317, July 2009.
- [6] S. Lu, Q. He, F. Hu, and F. Kong, "Sequential Multiscale Noise Tuning Stochastic Resonance for Train Bearing Fault Diagnosis in an Embedded System", *IEEE Transactions on Instrumentation and Measurement*, Vol. 63, No. 1, pp. 106-116, Jan. 2014.
- [7] X. Jin, M. Zhao, T.W.S. Chow, and M. Pecht, "Motor Bearing Fault Diagnosis Using Trace Ratio Linear Discriminant Analysis", *IEEE Transaction on Industrial Electronics*, Vol. 61, No. 5, pp. 2441-2451, May 2014.
- [8] T. H. Loutas, D. Roulias, and G. Georgoulas, "Remaining Useful Life Estimation in Rolling Bearings Utilizing Data-Driven Probabilistic E-Support Vectors Regression", *IEEE Transactions on Reliability*, Vol. 62, No. 4, pp. 821-832, Dec. 2013.
- [9] V. T. Do and U. P. Chong, "Signal Model-Based Fault Detection and Diagnosis for Induction Motors Using Features of Vibration Signal in Two-Dimension Domain," *J. Mech. Eng.*, Vol. 57, No. 9, pp. 655-666, 2011.
- [10] R. M. Haralick, K. Shanmugam, and Its Hak Dinstein, "Textural Features for Image Classification", *IEEE Transactions on Systems, Man and Cybernetics*, Vol. SMC-3, No. 6, pp. 610-621, Nov. 1973.
- [11] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen, "Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps", *IEEE Trans. Neural Networks*, Vol 3, No. 5, pp. 698-713, Sep. 1992.
- [12] Do, V. T. and Chong, U.-P., "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, 2011.

저 자 소 개



장 원 철

2013: 울산대학교
컴퓨터정보통신공학부 공학사.
현 재: 울산대학교
전기전자컴퓨터공학과 석사과정.
관심분야: 고장진단, 임베디드시스템.
Email : nasha0339@gmail.com



김 종 면

1995: 명지대학교 전기공학과 공학사.
2000: University of Florida
전기컴퓨터공학과 공학석사.
2005: Georgia Tech
전기컴퓨터공학과 공학박사
현 재: 울산대학교
전기공학부 교수
관심분야: 임베디드 SoC, 병렬처리.
Email : jmkim07@ulsan.ac.kr