

## 음향 방출 신호와 히스토그램 모델링을 이용한 유도전동기의 베어링 결함 검출

장원철\*, 서준상\*, 김종면\*

### Bearing Faults Identification of an Induction Motor using Acoustic Emission Signals and Histogram Modeling

Won-Chul Jang\*, Jun-Sang Seo\*, Jong-Myon Kim\*

#### 요약

본 논문에서는 저속으로 회전하는 유도 전동기의 베어링 결함을 검출하기 위해 음향 방출 신호와 히스토그램 모델링을 이용하는 방법을 제안한다. 제안한 방법은 정규화된 결함 신호가 구성하는 히스토그램의 포락선을 모델링하여, 부분 상관 계수와 DET(Distance Evaluation Technique) 기법을 이용하여 결함 유형별 고유한 특징을 추출 및 선택한다. 추출된 특징을 SVR(Support Vector Regression) 분류기의 입력으로 사용하여 베어링의 내륜, 외륜 및 롤러 결함을 분류한다. 최적의 분류 성능을 위해 SVR 커널함수의 매개변수를 0.01에서 1.0까지 변화시키고, 특징 개수는 2에서 150까지 변화시키면서 실험한 결과, 0.64-0.65의 매개변수와 75개의 특징 개수에서 제안한 방법은 약 91%의 분류 성능을 보였고, 또한 기존의 결함 분류 알고리즘보다 높은 분류 성능을 보였다.

▶ Keywords : 베어링 결함 검출, 유도 전동기, 음향 방출 신호, 편 상관 계수, 히스토그램 모델링, DET, SVR

#### Abstract

This paper proposes a fault detection method for low-speed rolling element bearings of an induction motor using acoustic emission signals and histogram modeling. The proposed method performs envelop modeling of the histogram of normalized fault signals. It then extracts and selects significant features of each fault using partial autocorrelation coefficients and distance evaluation technique, respectively. Finally, using the extracted features as inputs, the support vector regression (SVR) classifies bearing's inner,

•제1저자 : 장원철 •교신저자 : 김종면

•투고일 : 2014. 6. 26, 심사일 : 2014. 7. 4, 게재확정일 : 2014. 9. 19.

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

※ This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education, Science and Technology (NRF-2012R1A1A2043644)

outer, and roller faults. To obtain optimal classification performance, we evaluate the proposed method with varying an adjustable parameter of the Gaussian radial basis function of SVR from 0.01 to 1.0 and the number of features from 2 to 150. Experimental results show that the proposed fault identification method using 0.64-0.65 of the adjustable parameter and 75 features achieves 91% in classification performance and outperforms conventional fault diagnosis methods as well.

- ▶ Keywords : bearing fault detection, induction motor, acoustic emission signals, partial correlation coefficients, histogram modeling

## I. 서 론

산업 현장의 자동화 공정 전반에 사용되는 유도 전동기는 단순 구조와 견고한 내구성으로 구성된 장비이다. 공정과 장비의 대규모화에 따라 장비의 고출력, 고용량화로 유도 전동기 결함에 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 결함 중 가장 많은 비중을 차지하는 것은 베어링 결함으로, 베어링에서 발생한 결함을 사전에 예지하고 적절한 시기에 정비하지 못할 경우 유도 전동기의 다른 결함도 야기할 수 있는 문제점을 가지고 있어, 최근에는 베어링 결함을 조기에 예지하기 위한 연구가 활발히 진행되고 있다 [4-8].

기존 연구에서는 유도 전동기에서 취득한 진동 신호 및 전류 신호를 STFT(Short Time Fourier Transform), WPT(Wavelet Packet Transform), EMD(Empirical Mode Decomposition) 등의 신호처리 기법들을 사용하여 주파수 영역으로 변환하여 결함의 특징 주파수를 표현하는 방법이 제안되었다 [9-12]. 그러나 저속으로 회전하는 유도 전동기의 경우 베어링의 결함의 발생 주기가 상대적으로 긴 특성이 있어, 주파수 영역으로 변환하여 신호처리 기법을 적용할 경우 특징 주파수의 표현이 매우 미비하게 나타날 수 있다. 또한 취득되는 신호의 비정상(non-stationary)적인 특징으로 결함 신호가 항상 동일한 구간에서 발생한다는 보장을 할 수 없어 결함의 특징을 포함하는 주파수 분해 단계나 구간 선택에 대한 기준을 명확히 규정할 수 없다.

따라서 잠음에 약하지만 미세한 결함에도 결함의 고유한

신호적 특징이 잘 반영되는 음향 방출(Acoustic Emission) 신호를 이용하여 저속으로 회전하는 유도 전동기의 결함 신호가 갖는 평균적인 포락선의 모습을 분석하여 전술한 신호 분해 단계 및 구간 선택의 문제점들을 극복하고자 한다.

본 논문에서는 음향 방출 신호를 256단계로 정규화하여 결함 신호 정보의 히스토그램(Histogram)이 구성하는 포락선을 특징으로 간주하여 모델링한다. 모델링된 결함 신호에서 부분 상관 계수(Partial Autocorrelation Coefficients, PARCOR)를 사용하여 모델링된 포락선의 특징을 추출하고, DET(Distance Evaluation Technique)로 결함 신호 고유의 특성을 나타내는 특징을 선택한다. 모델링된 신호에서 추출된 특징 정보를 SVR(Support Vector Regression)의 입력으로 사용하여 베어링의 결함 상태를 분류한다. 각 결함 신호는 초당 0.5MHz로 샘플링되어 135개 데이터 셋으로 구성되었으며, 이 중 45개의 음향 신호는 분류기의 기계 학습에 사용하였고 나머지 90개를 제한한 알고리즘의 성능 검증을 위한 테스트 데이터로 사용하였다.

본 논문의 구성은 다음과 같다. 2장에서는 제안하는 결함 검출 알고리즘에 대해 설명하고, 3장에서는 베어링의 결함 신호와 히스토그램 모델링 결과에 대해 분석한다. 4장에서는 결함 신호에서 추출한 특징을 SVR의 입력으로 사용하여 베어링 결함의 분류 성능 결과를 분석한다. 마지막으로 5장에서는 본 논문의 결론을 맺는다.

## II. 기존 연구의 문제점 및 한계

기존의 베어링 결함 검출 연구는 취득된 신호를 주파수 영역으로 변환하여 결함 신호가 나타내는 특징 주파수의 표현을 이용하거나, 2차원 영상으로 변환하여 키포인트 기술자를 적

용하여 특징을 추출하는 방법이 제안되었다[15][16]. 그러나 주파수 영역에서의 특징 표현은 베어링의 결함이 미세한 경우 그 표현이 미비하여 잡음과의 구분이 힘든 단점이 있다. 또한 결함 발생 주기의 변화로 인해 주파수 영역에서의 표현은 주파수를 표현하는 노드규정과 구간선택의 문제점이 있다 [15]. 주파수 영역으로 변환하여 결함을 분류하는데 생기는 문제점을 극복하기 위해 2차원 영상 데이터로 변환하여 영상이 표현하는 질감을 분석하는 방법이 제안되었으나 [16], 취득된 신호에 잡음이 많아질 경우 신호의 왜곡으로 인해 기술자가 추출한 특징이 결함 신호의 고유성분을 제대로 반영하지 못하며, 취득된 신호의 결함이 미비한 경우 질감 영상으로 제대로 표현되지 않는 문제점이 있다.

### III. 제안하는 베어링 결함 알고리즘

전술한 문제점을 극복하기 위해 본 연구에서는 히스토그램 모델링을 적용하여 베어링의 결함을 분류하는 알고리즘을 제안한다. 그림 1은 본 연구에서 제안하는 베어링 결함 검출 알고리즘의 흐름도를 보여준다. 입력된 음향 방출 신호를 256 단계로 정규화한 후, 신호를 구성하는 히스토그램의 포락선을 모델링한다. 모델링된 음향 신호는 PARCOR와 DET를 사용하여 결함 신호의 특징을 추출 및 선택한다. DET를 사용하여 선택된 특징은 SVR의 입력으로 사용하여 베어링의 상태를 진단한다.

#### 1. 음향 신호의 히스토그램 모델링

제안하는 알고리즘에서 입력된 음향 방출 신호는 256단계로 정규화 하는 단계를 거쳐 신호를 구성하는 히스토그램을 모델링한다. 그림 2는 입력된 신호가 모델링되는 예를 보여준다.




그림 2. 음향 방출 신호의 모델링 예  
Fig. 2. Example of acoustic emission signals modeling

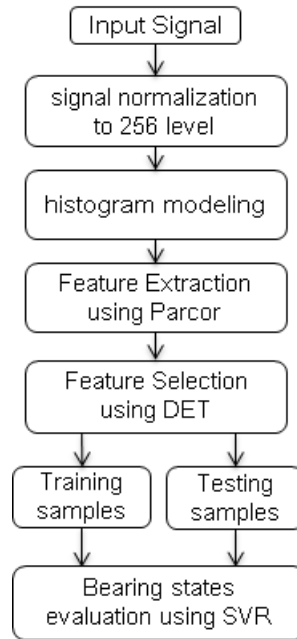


그림1. 베어링 결함 검출 알고리즘 흐름  
Fig. 1. Proposed bearing fault diagnosis scheme

다. 입력된 음향 방출 신호(그림 2(a))는 정규화 과정을 통해 그림 2(b)와 같이 256단계의 히스토그램을 구성하게 되며, 구성된 히스토그램에서 피크를 특징으로 간주하여 그림 2(c)와 같이 포물선을 모델링한다.

#### 2. 특징 추출과 선택

모델링된 결함 신호는 과거의 표본과 현재의 입력된 표본 간의 상관관계를 모델링하는 방법 중 하나인 PARCOR를 사용하여 결함 신호의 포락선을 대상으로 특징을 추출한다.

PARCOR는 선형 예측 코딩(Linear Predictive

Coding, LPC)에 비해 잡음에 의한 미세한 변화가 생기는 신호에도 비교적 균일하게 특징 벡터를 추출할 수 있는 장점이 있다. 본 논문에서는 신호 취득 시 잡음에 의해 생길 수 있는 데이터의 미세한 변화를 고려하여 PARCOR를 특징 벡터 추출에 사용한다.

추출된 특징 벡터는 DET를 통해서 결합 고유의 특징이 선택되고, 이는 분류기의 분류 기준 생성에 방해가 될 수 있는 관계없는(Irrelevant) 데이터 및 잉여 데이터들을 제거하는 효과를 얻을 수 있다. DET를 사용하여 고유한 특징을 선택하는 과정은 아래와 같다 [13].

학습 데이터에서  $C$ 개 유형의 특징 집합이 있다고 가정할 때 식 (1)과 같이 나타낼 수 있다.

$$q_{m,c,j}; m = 1, 2 \dots M_c \quad (1)$$

$$c = 1, 2 \dots C; j = 1, 2 \dots J$$

여기서  $q_{m,c,j}$ 는  $c$ 번째 유형이 갖는  $j$ 번째 고유 값의  $m$ 번째 표본을 나타낸다.  $M_c$ 는  $c$ 번째 유형의 표본수를 나타내며,  $J$ 는 각 표본의 개수를 나타낸다. 그러므로  $C$ 개 클래스에서는 총  $M_c \times C \times J$ 개 표본을 얻을 수 있다. 식 (1)을 활용하여 다음과 같이 최적의 특징을 선정할 수 있다.

식 (2)에서와 같이 동일 조건 내에 있는 표본 간 평균 거리를 계산한다. 계산된 결과로 최종  $C$ 유형의 평균 거리는 식 (3)과 같이 나타낼 수 있다.

$$d_{c,j} = \frac{1}{M_c(M_c - 1)} \sum_{l,m=1}^{M_c} q_{m,c,j} - q_{l,c,j} \quad (2)$$

$$l, m = 1, 2 \dots C; j = 1, 2 \dots J$$

$$d_j^{(w)} = \frac{1}{C} \sum_{c=1}^C d_{c,j} \quad (3)$$

여기서  $d_j^{(w)}$ 의 분산 계수는 식 (4)로 정의된다.

$$v_j^{(w)} = \frac{\max(d_{c,j})}{\min(d_{c,j})} \quad (4)$$

동일 유형 내 모든 표본의 평균 고유 값은 식 (5)로 계산된다.

$$u_{c,j} = \frac{1}{M_c} \sum_{m=1}^{M_c} q_{m,c,j} \quad (5)$$

이전 단계에서 계산된 결과를 식 (6)에 적용하여 다른 유형 표본 간의 평균 거리를 구한다.

$$d_j^{(b)} = \frac{1}{C(C-1)} \sum_{c,e=1}^C |u_{e,j} - u_{c,j}|, \quad (6)$$

$$c, e = 1, 2 \dots C, c \neq e.$$

식 (6)의  $d_j^{(b)}$ 의 분산 계수는 아래 식 (7)에 의해 정의되고, 식 (8)을 통해 보정 계수가 계산된다.

$$v_j^{(b)} = \frac{\max(u_{e,j} - u_{c,j})}{\min(u_{e,j} - u_{c,j})}, \quad (7)$$

$$c, e = 1, 2 \dots C, c \neq e.$$

$$\lambda_j = \frac{1}{\frac{v_j^{(w)}}{\max(v_j^{(w)})} + \frac{v_j^{(b)}}{\max(v_j^{(b)})}}. \quad (8)$$

식 (8)의 보정계수와 식 (3)과 (6)에서 계산된  $d_j^{(b)}$ ,  $d_j^{(w)}$ 을 사용하여 식 (9)와 같이  $\alpha_j$ 를 계산한다. 계산된  $\alpha_j$ 는 식 (10)을 통해 정규화된  $\bar{\alpha}_j$ 로 계산되고, 이를 사용하여 효과적으로  $C$ 유형의 특징들을 분리하여 선정할 수 있다. 본 논문에서는 특징 선정 개수에 변화를 주어 최적의 특징 선정 개수를 선택한다.

$$\alpha_j = \lambda_j \frac{d_j^{(b)}}{d_j^{(w)}}. \quad (9)$$

$$\bar{\alpha}_j = \lambda_j \frac{\alpha_j}{\max(\alpha_j)}. \quad (10)$$

### 3. 특징 분류

SVR은 SVM(Support Vector Machine, SVM)이 가지는 이진 분류기의 한계를 극복하고, 다양한 데이터를 효과적으로 분류할 수 있는 장점이 있다.

SVR의 분류 원리는 아래와 같다. 식 (11)과 같은 학습 데이터 집단이 있다고 가정할 때, SVR은 모든 학습 데이터에 대해 실제 목표 값이  $y$ 로부터 작은 편차와 가중치 벡터  $\omega$ 를 가지는  $f(x)$ 를 찾는 것이다.

$$(x_1, y_1), \dots (x_n, y_n) \subset \chi \times R \quad (11)$$

여기서,  $n$ 은 학습 데이터 개수이고,  $x$ 는 입력 벡터,  $y$ 는 출력벡터,  $\chi$ 는 입력공간 ( $\chi = R^d$ )을 나타낸다. 이와 같은 조건을 만족하는 선형함수  $f(x)$ 는 식 (12)와 같다.

$$f(x) = \langle \omega, x \rangle + b \text{ with } \omega \in \chi, b \in R \quad (12)$$

여기서  $b$ 는 바이어스이며,  $\langle \omega, x \rangle$ 는 입력공간에 대한 내적이다. 대부분의 경우 분류기에 주어진 자료가 선형적으로 분류되지 않는 문제점을 지니고 있는데, 이를 극복하기 위해 커널 함수 (kernel function)를 이용하여 주어진 데이터를 고차원의 공간으로 사상시켜 분류한다.


분류기에 사용되는 대표적인 커널 함수로 polynomial function, RBF (Gaussian radial basis function) 등이 있으며, 본 논문에서는 식 (13)과 같이 일반적으로 좋은 분류 성능을 보이는 RBF를 이용하였다 [14].

$$k(sv_i, sv_j) = \exp\left(-\frac{\|sv_i - sv_j\|^2}{2\sigma^2}\right) \quad (13)$$


여기서  $sv_i, sv_j$ 는 입력 특징 벡터이며,  $\sigma$ 는 효과적인 폭 (Margin)을 결정하기 위한 매개 변수이다.  $\sigma$ 값에 따라 분류 성능에 영향을 미치므로 본 논문에서는 결함 유형을 분류하는 최적의  $\sigma$ 값을 선택한다.

#### IV. 결함 신호 분석 및 실험

##### 1. 결함 신호 분석



(a) 20RPM



(b) 140RPM

그림 3. RPM별 내륜 결함

Fig. 3. Inner race defeat of 20 RPM and 140 RPM

그림 3은 20RPM과 140RPM에서 회전하는 유도 전동기의 내륜 결함 신호를 초당 0.5MHz로 샘플링하여 주파수 영역에서 표현한 스펙트럼 일부를 보여준다. 그림 3 (b)에서 보는 바와 같이 140RPM에서 회전하는 유도 전동기의 베어링 내륜 결함은 주파수 영역에서 특징 주파수가 잘 표현되는데 반해 20RPM(그림 3 (a)) 경우 노이즈와 특징 주파수의 구분이 어렵다. 그림 3 (a)처럼 저속으로 회전하는 유도 전동기의 베어링 결함 신호를 주파수 영역으로 변환하면 결함을 나타내는 특징이 매우 미비하게 표현 될 수 있음을 알 수 있다.

그림 4는 20RPM에서 회전하는 유도 전동기의 베어링 내륜 결함 신호를 대상으로 신호 분해 기법으로 각 노드에서 표현된 결과를 보여준다. 신호 발생주기가 일정하지 않음에 따라 각 노드간의 주파수 표현이 일정하지 못함을 알 수 있다. 그림 3과 4의 결과로 저속으로 회전하는 유도전동기의 경우 주파수 영역에서 신호를 분해하여 노드를 선택하는 방법이 결함 특징에 대한 매우 미비한 주파수 표현과 발생 주기의 일정함을 보장할 수 없는 문제점으로 발생 주기의 오차에 대한 추가적인 모델링이나 오차 범위에 대한 신호처리 기법이 요구된다. 하지만, 신호의 히스토그램의 포락선을 모델링하면 결함의 특징 발생 주기가 다소 일정하지 않더라도 히스토그램을 구성하는 정보가 동일 유형에서는 유사하게 나타나므로 정규화된 신호의 포락선을 모델링하면 결함 신호 발생 주기 및 간격에 대한 오차나 결함 특성이 미비하게 표현되더라도 추가적인 모델링이나 분석 기법이 요구되지 않는 장점이 있다.




그림 4. 노드별 내륜 결함  
Fig. 4. Inner race defect in FFT nodes




그림 5. 결함 유형별 히스토그램 모델링  
Fig. 5. Histogram modeling of each defeat cases

그림 5는 베어링의 내륜, 외륜 및 롤러 결함에 대한 각 유형의 평균적인 포락선 모델링 결과를 보여주는데, 각 결함 유형의 포락선이 독립적임이고 각각의 유형을 구성하는 히스토그램 정보가 상이함을 알 수 있다. 본 논문에서는 저속으로 회전하는 유도 전동기의 베어링 결함을 대상으로 노드 선택의

문제점과 오차 범위에 대한 추가적인 모델링 요구 사항을 극복하기 위해 히스토그램 구성 정보를 이용하여 모델링한 신호의 특징 벡터를 사용하여 베어링의 결함 상태를 진단한다.

## 2. 실험 및 결과

실험은 초당 0.5MHz로 샘플링된 결함 유형별 음향 방출 데이터를 1초 단위로 나누어 총 135개의 데이터 셋으로 구성하여 실험하였다. 이 중 45개의 데이터는 SVR의 기계학습에 사용하였고, 나머지 90개의 데이터를 분류기의 입력으로 사용하였다. 진술한 RBF 커널 함수의  $\sigma$ 값과 DET의 특징 개수 선택으로 최적의 분류 성능을 얻기 위해  $\sigma$ 값은 0.01에서 1.0까지, 특징 개수는 2개부터 150개까지 변화시키면서 실험하였다. 실험결과 최적의 분류를 위한 매개변수  $\sigma$ 는 0.64-0.65, 특징 개수는 75개임을 알 수 있었다.

표 1은 본 논문에서 제안하는 결함 검출 시스템과 기존에 제안된 결함 검출 알고리즘의 성능 비교를 보여준다 [15][16]. 표 1에서 TP(True Positive) rate는 입력된 결함 신호를 얼마나 해당 결함으로 잘 분류하는지에 대한 지표이다. 이들 알고리즘에 입력된 데이터를 최적의  $\sigma$ 값과 특징 개수를 사용하여 분류한 결과, 표 1에서 보는바와 같이 본 논

표 1. 알고리즘별 결함 분류 성능

Table 1. Fault classification accuracy using the proposed and conventional algorithms

		Inner race	Outer race	Roller	Average
제안 방법	True Positive rate(%)	93.75	92.53	89.10	91.79
알고리즘 1 (15)	True Positive rate(%)	91.27	90.70	88.57	90.18
알고리즘 2 (16)	True Positive rate(%)	87.50	91.27	85.35	88.04

문에서 제안하는 방법이 기존 알고리즘보다 높은 분류 성능을 보였다. 알고리즘 1은 WPT(Wavelet Packet Transform)를 적용하여 3단계 분해 과정을 거쳐 특징을 추출하고 DET를 이용하여 특징을 선택하였지만, 신호를 변환하는 과정에서 특징 주파수의 발생 주기가 일정하지 않아 추출한 특징이 결함 고유의 특성을 제대로 반영하지 못하였다. 알고리즘 2의 경우, 취득한 데이터에 포함된 노이즈로 인해 SIFT의 키포인트 기술자가 큰 변화를 야기하기 때문에 제안한 알고리즘에 비해 분류 성능이 떨어지는 결과를 보여준다.

표 1의 결과에서 물리 결함의 오분류율이 내륜, 외륜 결함에 비해 높음을 알 수 있는데, 이는 음향 신호를 취득하는 센서의 위치적 한계와 음향 신호의 특성으로 인한 것으로 판단된다. 음향 신호의 특성상 소리 에너지가 결함 발원지에서 센서로 전달되는 동안 인접한 구조물의 음향도 함께 포함될 수 있어 취득되는 샘플에 따라서는 결함이 생긴 구조물과 인접한 구조물의 특성이 둘 다 나타날 수 있기 때문이다. 따라서 향후 연구에서는 이러한 특성을 고려한 신호처리 기법이 요구된다.

## V. 결론

본 논문에서는 음향 방출 신호와 히스토그램 모델링 기법을 이용하여 지속적으로 회전하는 유도 전동기의 베어링 결함 검출 방법을 제안하였다. 제안한 방법은 음향 신호를 256단계의 정규화를 통해 각 결함 유형이 구성하는 히스토그램 정보의 포락선을 모델링하고, PARCOR 기법을 통해 각 결함별 특징을 추출한다. 추출된 특징을 DET를 이용하여 각 결함 유형별 고유한 특징을 선정하며, 이를 SVR의 입력으로 사용하여 베어링의 결함 유형을 분류하였다. SVR 커널함수의 최적인 매개 변수 값과 특징 수를 사용하여 입력된 결함 데이터의 분류 성능을 실험한 결과, 제안한 방법은 약 91%의 분류 성능을 보였고, 기존 방법들 보다 우수한 분류 성능을 보였다. 이러한 결과는 영상화된 음향 신호에서 모델링된 특징이 지속적으로 회전하는 유도 전동기의 베어링 결함 분류에 활용될 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] W. Jang, J. Kim "Bearing Multi-Faults Detection of an Induction Motor using Acoustic Emission Signals and Texture Analysis", *Journal of the Korea Society of Computer and Information*, Vol. 19, No. 4, pp. 55-62, 2014.
- [8] M. Kang, W. Jang, and J. Kim, "High-Reliable Classification of Multiple Induction Motor Faults using Robust Vibration Signatures in Noisy Environments based on a LPC Analysis and an EM Algorithm", *Journal of the Korea Society of Computer and Information*, Vol. 19, No. 2, pp. 21-30, 2014.
- [9] B. Robert and J. Antoni, "Rolling Element

- Bearing Diagnostics”, Mechanical System and Signal Processing, Vol. 25, No. 2, pp. 485-520, 2011.
- [10] N. Baydar and A. Ball, “Detection of Gear Failures via Vibration and Acoustic Signals using Wavelet Transform”, Mechanical System and Signal Processing, vol. 17, no. 4, pp. 787-804, 2003.
- [11] H. E. Jeong, D. S. Gu, H. J. Kim, Tan. Andy, Y. H. Kim and B. K. Choi, “The Application of AE Transducer for the Bearing Condition Monitoring of Low-Speed Machine”, KSNVE07S-09-03, 2007.
- [12] D. Wang, Q. Miao and R. Kang, “Robust Health Evaluation of Gearbox Subject to Tooth Failure with Wavelet Decomposition”, Journal of Sound and Vibration, vol. 324, pp. 1141-1157, 2009.
- [13] Yaguo Lei, Zhengjia He, Yanyang Zi, Qiao Hu, “Fault Diagnosis of Rotating Machinery based on Multiple ANFIS Combination with GAs”, Mechanical Systems and Signal Processing 21, pp. 2280-2294, 2007.
- [14] A.J. Smola, B. Scholkopf, “A Tutorial on Support Vector Regression”, Statistics and Computing 14, pp. 199-222, 2004.
- [15] C. Shen, D. Wang, F. Kong, P. W. Tse, “Fault Diagnosis of Rotating Machinery based on the Statistical Parameters of Wavelet Packet Paving and a Generic Support Vector Regressive Classifier”, Journal of the International Measurement Confederation 46, pp. 1551-1564, 2013.
- [16] 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,” 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, 임베디드 SoC.  
Email : nasha0339@gmail.com



### 서 준 상

2013: 울산대학교  
컴퓨터정보통신공학부 공학사.  
현 재: 울산대학교  
전기전자컴퓨터공학과 석사과정.  
관심분야: 병렬프로세서 구조,  
임베디드시스템,  
화재감지 알고리즘  
Email : Siberiaj00@gmail.com



### 김 중 먼

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