

# SVM을 이용한 웨이블릿기반 프로파일 분류에 관한 연구

## A Wavelet-based Profile Classification using Support Vector Machine

김성준

Seong-Jun Kim

강릉대학교 산업시스템공학과

### 요약

베어링은 각종 설비에서 활용되는 중요한 기계요소 중 하나이다. 설비고장의 상당수는 베어링의 결함이나 파손에 기인하고 있다. 따라서 베어링에 대한 온라인 모니터링 기술은 설비의 정지를 예방하고 손실을 줄이는 데 필수적이다. 본 논문은 진동신호를 이용하여 베어링의 상태를 예측하기 위한 온라인 모니터링에 대해 연구한다. 프로파일로 주어지는 진동신호는 이산 웨이블릿 변환을 통해 분석되고, 분해수준별 웨이블릿 계수로부터 얻은 통계적 특징 중 유의한 것을 선별하고자 분산분석(ANOVA)을 이용한다. 선별된 특징벡터는 Support Vector Machine (SVM)의 입력이 되는데, 본 논문에서는 다중클래스 분류 문제를 다루기 위한 계층적 SVM 트리를 제안한다. 수치실험 결과, 제안된 방법은 베어링의 결함을 분류하는 데 우수한 성능을 갖는 것으로 나타났다.

키워드 : 웨이블릿, 프로파일 분류, 통계적 특징, Support Vector Machine, 특징선택

### Abstract

Bearing is one of the important mechanical elements used in various industrial equipments. Most of failures occurred during the equipment operation result from bearing defects and breakages. Therefore, monitoring of bearings is essential in preventing equipment breakdowns and reducing unexpected loss. The purpose of this paper is to present an online monitoring method to predict bearing states using vibration signals. Bearing vibrations, which are collected as a form of profile signal, are first analyzed by a discrete wavelet transform. Next, some statistical features are obtained from the resultant wavelet coefficients. In order to select significant ones among them, analysis of variance (ANOVA) is employed in this paper. Statistical features screened in this way are used as input variables to support vector machine (SVM). An hierarchical SVM tree is proposed for dealing with multi-class problems. The result of numerical experiments shows that the proposed SVM tree has a competent performance for classifying bearing fault states.

Key Words : Wavelet, Profile Classification, Statistical Features, Support Vector Machine, Feature Selection

### 1. 서 론

산업현장에서 각종 설비의 실시간 모니터링은 품질 및 생산성 측면에서 매우 중요한 이슈다. 설비가 이상을 일으키면 불량품이 대량으로 발생하게 되고 또한 고장으로 인한 설비의 운전중단은 많은 비용을 수반하기 때문이다. 따라서 운전에 영향을 미치지 않으면서 설비의 문제점을 조기에 검출하고 진단하는 문제는 많은 연구의 대상이 되어왔다 [1].

베어링은 회전운동을 요하는 각종 설비에 들어가는 중요한 기계요소 중 하나이다. 설비운전 중 발생하는 문제점의 상당수가 바로 베어링의 결함 때문으로 알려져 있다. 스크

래치, 크랙, 변형 등 베어링의 결함은 피로, 노후화, 하중의 변동, 운전조건의 이상 등에 의해 나타나게 된다. 특히 주기적 접촉에 의한 피로 스트레스는 메탈 베어링 크랙의 주요 원인으로 나타나고 있다[1-3].

베어링의 실시간 모니터링에는 보통 진동, 음파, 온도, 힘, 토크 등과 같은 신호가 이용되지만 구조역학과 직접적인 관계가 있고 측정이 용이하며 정보전달량이 많은 진동신호가 널리 활용되고 있다[4]. 예를 들어 Sugumaran et al. (2007, 2008)은 진동신호를 이용하여 4가지의 결합패턴을 분류하는 방법을 연구하였다. 이 때 진동신호로부터 시간영역의 특징을 추출하기 위한 방안으로서 평균 (Mean), 표준 편차 (Standard Deviation), 중위수 (Median), 범위 (Range), 왜도 (Skewness), 침도 (Kurtosis) 등과 같은 통계적 특징의 활용을 제안하였다. 이러한 통계적 특징추출방법은 Hu et al. (2007)이나 Rafiee et al. (2007)의 연구에서도 활용되었다. 그러나 Yan and Gao (2005)는 시간영역신호를 그대로 다루는 것은 노이즈에 취약하고 간섭에 영향을 쉽게 받으므로 실시간 모니터링 문제에는 한계가 있음을 지적하였다. 따라서 웨이블릿변환을 이용함으로써 진동과 같

접수일자 : 2008년 4월 4일

완료일자 : 2008년 6월 26일

\* 교신 저자

본 논문은 2007년도 정부재원 (교육인적자원부 학술연구조성사업비)으로 한국학술진흥재단의 지원을 받아 연구되었음 (KRF-2007-521-D00545).

이 비정상적인 신호를 보다 효과적으로 처리할 수 있음을 보였다. Hu et al. (2007)도 역시 웨이블릿변환을 통한 주파수영역에서의 진동신호분석을 수행하였다.

베어링의 상태를 분류하기 위해 ANN (Artificial Neural Network)과 SVM (Support Vector Machine) 등의 널리 이용되고 있다[6]. Rafiee et al. (2007)은 MLP (Multi-layer Perceptron)에 의하여 5가지 베어링 상태를 분류하는 방안에 대해 연구하였다. 하지만 ANN 분류기의 성능은 학습데이터에 의존하는 경향이 강해 일반화능력이 상대적으로 저하된다는 문제점이 있어 최근에는 SVM을 적용하는 사례가 늘고 있다. 예를 들어, Hu et al. (2007)과 Sugumaran et al. (2007, 2008) 등은 베어링의 진동패턴을 실시간으로 분류하기 위해 SVM을 이용하였다. Yan and Gao (2005)도 4가지의 베어링 결함을 다루기 위한 MLP와 RBF (Radial Basis Function) 분류기의 적용에 대해 연구하고 그 분류성능을 비교한 바 있다. 이외에도, 베어링의 상태에 대한 애매성을 함께 모델링하기 위해 Sugumaran and Ramachandran (2007)은 퍼지분류기법을 제안하기도 하였다.

그림 1에 나타낸 바와 같이, 본 논문에서는 진동신호로부터 베어링의 상태를 실시간으로 분류하기 위한 웨이블릿기반 SVM을 제안하고자 한다.

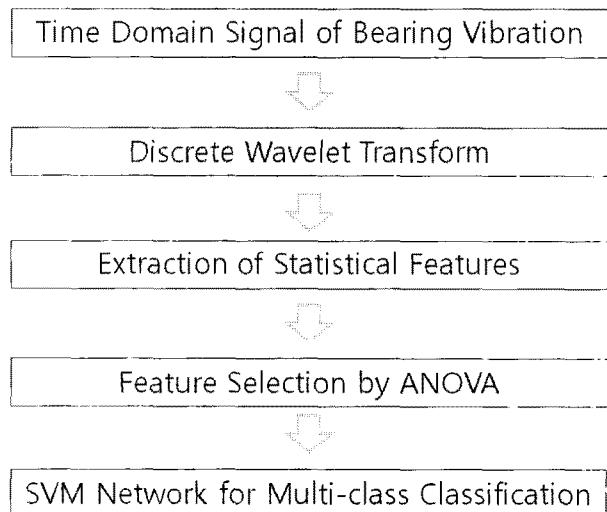


그림 1. 온라인모니터링을 위한 웨이블릿기반 SVM  
Figure 1. SVM for online monitoring proposed in the present study

다른 연구와는 달리 통계적 특징추출을 웨이블릿영역에서 수행하는 것이 특징이며, 또한 SVM 학습에 요구되는 지배적 특장을 선별하기 위해 통계적인 방안으로서 분산분석 (Analysis of Variance)을 이용하는 절차를 제시하고자 한다. 아울러 Sugumaran et al. (2007, 2007)의 진동실험데이터를 이용하여 제안된 방법의 분류성능을 살펴보고자 한다.

## 2. 진동프로파일 특징 추출

베어링의 실시간 모니터링 관련해서 최근 Sugumaran 등이 수행한 일련의 연구에서는 진동신호 프로파일로부터

통계적 특징을 추출하는 방법이 채택되었다. 시점  $t_i$ 에서 관측된 진동신호를  $x_i$ 라고 할 때 추출된 통계적 특징은 다음과 같다[1-3]. 단  $i = 1, 2, \dots, n$ 이며  $n$ 은 추출된 진동신호의 표본크기이다.

(a) Sum 혹은 Mean

$$T = \sum_{i=1}^n x_i \text{ or } \bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

(b) Standard deviation

$$s = \sqrt{(n\sum x^2 - T^2)/n(n-1)}$$

(c) Sample variance

$$s^2 = (n\sum x^2 - T^2)/n(n-1)$$

(d) Standard error

$$s_e = \left( \sum(x - \bar{x})^2 - \frac{\sum(t - \bar{t})(x - \bar{x})}{\sum(t - \bar{t})^2} \right)^{1/2} / \sqrt{n-2}$$

(e) Skewness

$$m_3 = \frac{n}{(n-1)(n-2)} \sum \left( \frac{x - \bar{x}}{s} \right)^3$$

(f) Kurtosis

$$m_4 = \frac{n(n+1)\sum(\frac{x - \bar{x}}{s})^4 - 3(n-1)^3}{(n-1)(n-2)(n-3)}$$

(g) Minimum value

$$x_{\min} = \min(x_i | i = 1, 2, \dots, n)$$

(h) Maximum value

$$x_{\max} = \max(x_i | i = 1, 2, \dots, n)$$

(i) Range

$$R = x_{\max} - x_{\min}$$

Sugumaran et al. (2007, 2008)은 그림 2와 같이 얻어진 진동신호에 대해 위와 같은 통계적 특징을 추출한 후 의사결정나무 (Decision Tree)를 이용하여 주요 특징을 선별하였다. 연구결과에 따르면 Standard error, Skewness, Kurtosis, Minimum 등 4가지의 특징이 주요한 것으로 나타났으며, 이들을 SVM의 특징벡터로 활용하였다.

한편 이와 같은 통계적 특징추출방법은 Rafiee et al. (2007)의 연구에서도 등장하였다. 그들은 5가지 모드의 진동신호에 대해 웨이블릿패킷변환을 적용한 후 각 분해수준마다 웨이블릿계수로부터 계산된 표준편차를 특징벡터로 이용하였다. 하지만 웨이블릿패킷 분해수준 전체가 특징벡터에 포함되는 것은 효율성을 저하시킬 수 있으므로 특징선택절차에 보완이 있어야 할 것으로 판단된다.

이처럼 여러 연구에서 통계적 특징추출방법이 채택되고 있으나 패턴분류문제에의 적합성에 대해서는 좀 더 면밀한 검토가 필요할 전망이다. 왜냐하면 통계적 특징은 노이즈의 크기에 민감하게 반응하기 때문이다. 이를 예시하기 위해, 그림 2의 진동신호를 Baseline으로 하고 여기에

Gaussian Noise를 가미시켜 Simulated Signal을 생성한 후 통계적 특징을 추출하였다. 그 결과의 일부로서 그림 3은  $\sigma$ 의 크기에 따른 진동신호의 Minimum value와 Skewness 계산결과를 도시하고 있다. 4개의 프레임은 (a)  $x_{\min}$  at  $\sigma = 10$ , (b)  $x_{\min}$  at  $\sigma = 25$ , (c)  $m_3$  at  $\sigma = 10$ , (d)  $m_3$  at  $\sigma = 25$ 를 각각 나타낸다.  $x_{\min}$ 의 경우,  $\sigma = 10$ 일 때에는 4가지 진동신호가 뚜렷하게 구별되고 있지만  $\sigma = 25$ 로 증가했을 때에는 Fault 2와 Fault 3은 잘 구별되지 않는다.  $m_3$ 의 경우도 마찬가지로서  $\sigma = 10$ 일 때보다는  $\sigma = 25$ 일 때 패턴의 구별능력이 현저하게 떨어지고 있음을 알 수 있다. 따라서 본 논문은 이러한 문제점을 보완하기 위해 웨이블릿변환을 이용하고자 한다.

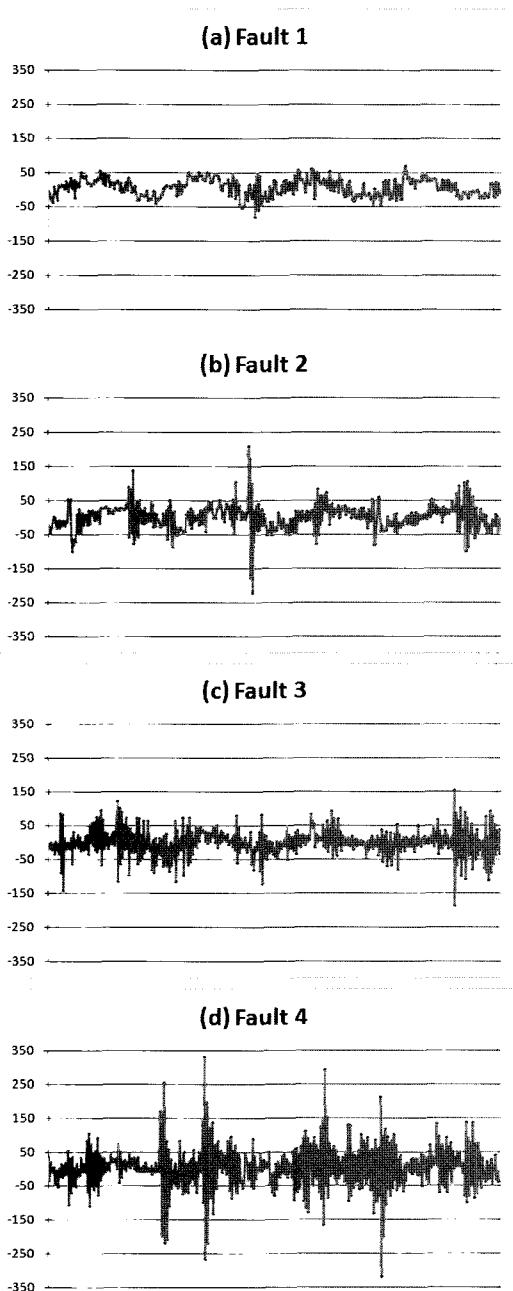


그림 2. 베어링 결합모드에 따른 진동신호 [1-3]  
Figure 2. Vibration signals from the fault bearing

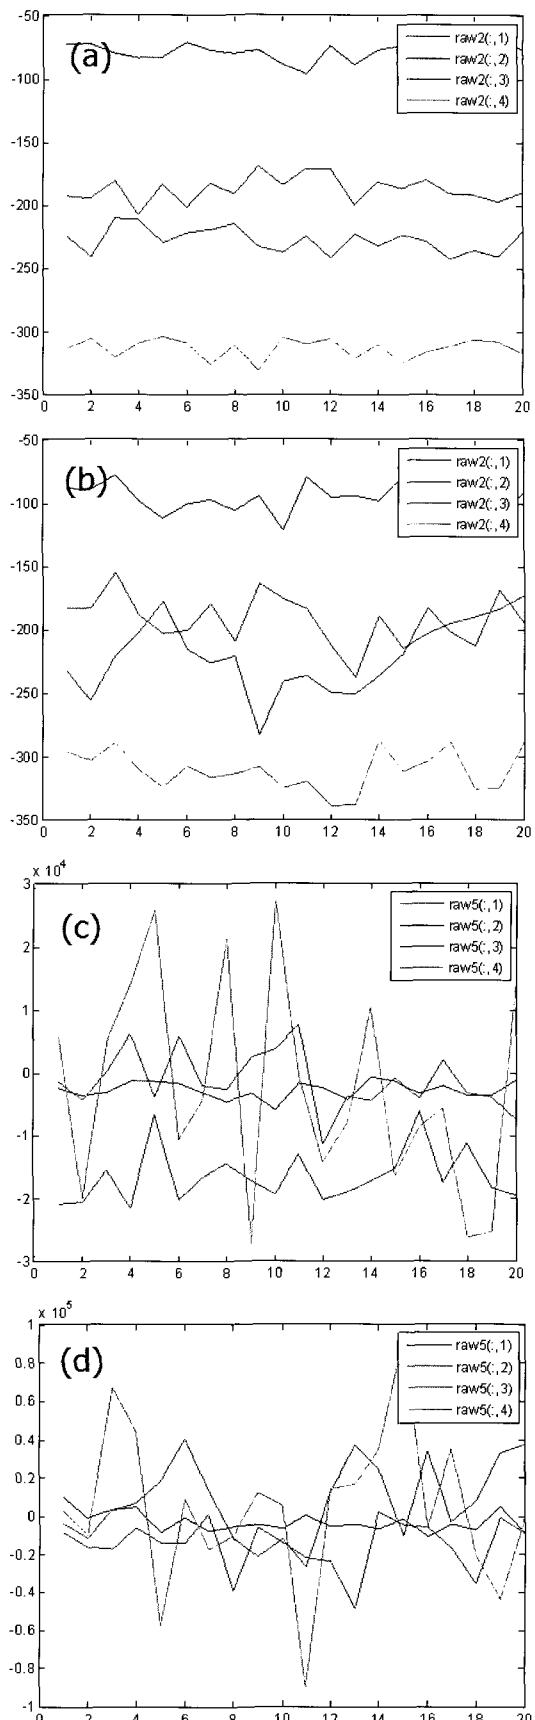


그림 3. 노이즈에 따른 통계적 특징추출  
Figure 3. Statistical feature extractions by noise

### 3. SVM을 이용한 진동프로파일 분류

#### 3.1 Support Vector Machine for Classifications

통계적 학습이론에 근거한 SVM은 Vladimir Vapnik[7]에 의해 이론적 체계를 갖춘 이래, 최근 패턴인식을 포함한 다양한 분야에서 분류, 회귀, 추정의 문제를 다루는 데 널리 활용되고 있다. 신경회로망 등 많은 방법이 Empirical Risk Minimization에 기초하고 있는 반면 SVM은 Structural Risk Minimization에 기초한다. 이런 연유로, SVM 쪽이 보다 적은 학습데이터로도 더 나은 일반화능력을 보여줄 수 있으며 신경회로망의 유망한 대안으로 주목받고 있다[8].

SVM은 클래스 간의 최소거리를 최대화하는 초평면 (Hyperplane)을 찾아냄으로써 클래스를 분류하는 방법이다. 만약 클래스를 최적으로 분리하는 초평면 (Optimal Separating Hyperplane, OSH)이 존재하지 않을 경우에는 원 데이터를 보다 높은 차원의 공간으로 사상시키고 새로운 영역에서 OSH를 찾게 된다. 이 개념을 그림으로 나타내면 다음과 같다.

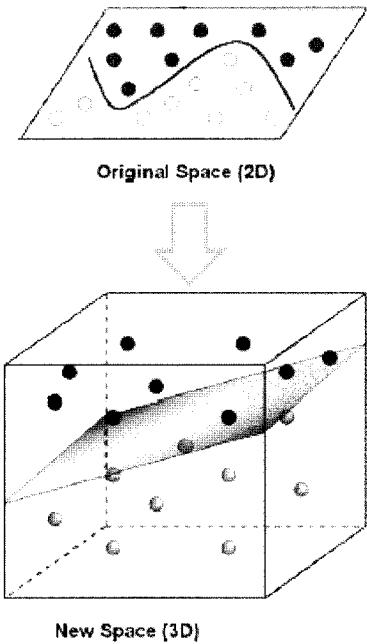


그림 4. 높은 차원의 특징공간에서 얻은 OSH

Figure 4. An Example of OSH Found in the Higher Dimensional Feature Space (Martinez-de-Pison et al., 2008)

그림에서 보는 바와 같이, 원래 차원에서는 OSH 대신 복잡한 비선형 판별함수를 이용하여 클래스를 구분하고 있다. 판별함수가 복잡한 구조를 가지면 학습데이터에 대한 의존도가 높아져서 과적합(Over-fitting)이 발생하기 쉽고 따라서 분류의 일반화 능력도 저하된다. SVM은 이 문제를 해결하기 위해 비선형적인 변수변환을 이용한다. 보다 높은 차원에서는 그림과 같이 선형적인 판별함수 즉 OSH를 쉽게 찾을 수 있기 때문이다. 그러면 어떻게 이것이 가능한지를 좀 더 살펴보기로 한다. 먼저 학습데이터셋을  $D = \{(x_i, y_i) | i=1, 2, \dots, n\}$ 으로 나타낸다. 단  $x_i$ 는  $m$  차원의 특징벡터를 의미하고 클래스  $y_i \in \{-1, +1\}$ 를 갖는다.

SVM의 기본 아이디어는 다음 그림 5와 같이 두 클래스 간의 마진(Margin)을 최대화하는 초평면  $w^T x + b$ 를 찾는 것이다. 이 때 마진의 경계 상에 위치한 특징벡터를 Support Vector라고 부르며 그림에선 굵게 표시되어 있다.

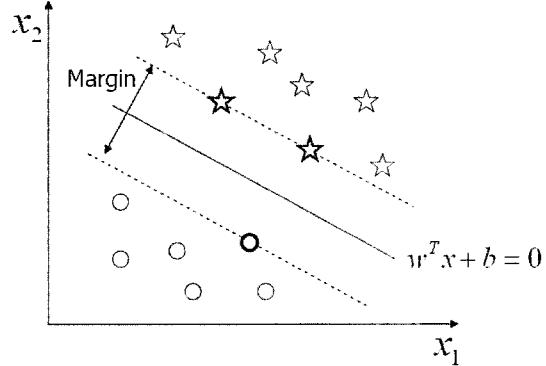


그림 5. SVM에 의한 분류  
Figure 5. Classification by SVM

그림에서, 임의의 특징벡터  $x_i$ 는 초평면  $w^T x + b$ 에 대해 다음을 만족한다.

$$y_i = \begin{cases} 1, & w^T x_i + b \geq 0 \\ -1, & w^T x_i + b < 0 \end{cases}$$

단  $i = 1, 2, \dots, n$ . 이를 좀 더 간단하게 쓰면

$$y_i(w^T x_i + b) \geq 1, \text{ for } i = 1, 2, \dots, n$$

과 같다. 따라서 OSH를 구하는 문제는 다음과 같은 최적화 문제로 표현된다.

$$\begin{aligned} \text{Minimize } \Phi(w) &= \frac{1}{2} w^T w \\ \text{s.t. } y_i(w^T x_i + b) &\geq 1 \text{ for } i = 1, 2, \dots, n \end{aligned}$$

여기서 최적해를 구하기 위해서는 라그랑지승수( $\lambda_1, \lambda_2, \dots, \lambda_n$ )을 이용하여 다음과 같이 쌍대문제로 바꿔 푸는 것이 효율적이다.

$$\begin{aligned} \max_{\lambda} & \left\{ -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j x_i^T x_j + \sum_{k=1}^n \lambda_k \right\} \\ \text{s.t. } & \lambda_i \geq 0 \text{ for } i = 1, 2, \dots, n \\ & \sum_{i=1}^n \lambda_i y_i = 0 \end{aligned}$$

그러면 다음과 같이 OSH 즉  $w^{*T} x + b^*$ 를 구할 수 있다.

$$\begin{aligned} w^* &= \sum_{i=1}^n \lambda_i y_i x_i \\ b^* &= -\frac{1}{2} w^{*T} (x_r + s_s) \end{aligned}$$

단  $x_r$ 과  $x_s$ 는  $\lambda_r, \lambda_s > 0$ 과  $y_r = -1, y_s = 1$ 을 만족하는 Support Vector이다.

하지만, 대부분의 분류문제는 선형적으로 분리되지 않을 때가 많다. 이 경우 SVM은 원 데이터를 고차원 공간으로

사상시키고 사상된 공간에서 OSH를 탐색하게 된다. 이를 위해 비선형적으로 사상된 결과를 벡터  $\phi(\cdot)$ 이라고 하면, 고차원 공간에서의 OSH는 다음처럼 구할 수 있다.

$$\sum_{i=1}^n \lambda_i y_i \phi(x_i)^T \phi(x) + b^*$$

여기서, 비선형사상의 결과인  $\phi(\cdot)$ 의 내적으로 써 다음과 같이 정의되는 함수를 커널 (Kernel)이라고 부른다.

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$$

여기서 흥미로운 사실은, 고차원 공간에서 OSH를 찾고자 할 때 개별적인  $\phi(x_i)$ 와  $\phi(x_j)$ 를 모두 알아야 할 필요가 없고 단지 커널함수  $K(x_i, x_j)$ 만 알고 있으면 충분하다는 것이다. 이러한 성질을 커널트릭 (Kernel Trick)이라고 부르는데 SVM의 장점 중 하나는 개별적인 비선형변환 결과와 관계없이 커널만으로 최적 분류가 가능하다는 데 있다. SVM에서 사용되는 대표적인 커널은 Polynomial Function, Gaussian Radial Basis Function, Exponential Radial Basis Function, Multi-layer Perceptron, Spline 등이 있다. 각 커널함수의 성질에 대해서는 Vapnik (1998)을 보기 바란다.

### 3.2 웨이블릿변환과 분산분석을 이용한 특징선택

시간영역의 진동신호로부터 그대로 통계적 특징을 추출하면 노이즈에 취약할 수 있음은 2장에서 설명한 바와 같다. 이에 본 연구에서는 이산웨이블릿변환을 적용한 후 분해수준 별로 웨이블릿계수를 분석하여 통계적 특징추출을 수행하기로 한다. 이를 위해 본 논문에서는 분해수준이 4인 Haar 웨이블릿을 이용한다.

각 분해수준에서 얻어진 통계적 특징을 모두 사용하는 것은 비효율적이므로 분해수준 별로 지배적 특징 (Dominant features)을 선별하는 것이 바람직하다. 이를 위한 방안으로 본 연구에서는 ANOVA (Analysis of variance)를 이용하기로 한다. 원래 ANOVA는 조건 별로 평균 값이 얼마나 변화하는지를 통계적으로 판단하는 방법이지만, 본 연구에서는 웨이블릿계수로 얻어진 특징추출값이 진동신호 패턴에 대해 얼마나 판별력이 큰지를 정량적으로 평가하기 위해 채용되었다. 여기서 판별력의 측도로서는 F-value를 이용하기로 한다. F-value가 크면 그룹 간의 차이가 뚜렷하다는 의미이므로 그만큼 높은 판별력을 갖는 것으로 해석할 수 있다. ANOVA와 F-value에 대한 더 자세한 내용은 참고문헌 [9]를 보기 바란다.

### 3.3 다중클래스 분류를 위한 SVM 트리

그러면 우선 웨이블릿변환과 ANOVA에 의해 유의한 특징을 선별한 결과에 대해 살펴보기로 한다. 통계적 특징 중 활용빈도가 높은  $x_{\max}$ ,  $x_{\min}$ ,  $\bar{x}$ ,  $s$ ,  $m_3$ ,  $m_4$ 에 대해 웨이블릿 분해수준 별로 ANOVA를 적용한 결과 다음 표 1과 같이 F-value를 얻었다. 아울러 각 수준 별로 F-value가 상대적으로 큰 곳에 밀줄을 그어 그 유의성을 표시하였다.

웨이블릿계수벡터를  $c = (a_4, d_4, d_3, d_2, d_1)$ 라고 할 때, 근사수준인  $a_4$ 에서는  $\bar{x}$ 가 유의한 것으로 판명되었고 Sugumaran *et al.* (2007, 2008)의 결과와는 달리  $x_{\min}$ 이나  $m_3$ 은 유의성의 매우 떨어지는 것으로 나타났다. 반면 상세수준에서는 표본표준편차  $s$ 의 역할이 두드러진다. 이것은

상세수준 전체인  $(d_4, d_3, d_2, d_1)$ 에서 크게 유의하였다. 이외에도,  $d_3$ 에서는  $x_{\max}$ 의 효과가 유의하였고  $d_1$ 에서는 다시  $\bar{x}$ 가 유의한 것으로 나타났다.

표 1. 통계적 특징에 대한 분산분석 결과

Table 1. ANOVA results of selected statistical features

F-value	a4	d4	d3	d2	d1
$x_{\max}$	228.95	90.29	<u>2820.85</u>	1240.09	4415.72
$x_{\min}$	63.31	38.59	232.95	1548.07	4902.97
$\bar{x}$	<u>980.17</u>	15.94	41.39	116.21	<u>21188.25</u>
$s$	504.6	<u>328.32</u>	<u>2593.22</u>	<u>4606.12</u>	<u>33133.43</u>
$m_3$	5.58	38.38	999.62	312.46	8084.16
$m_4$	213.22	159.23	709.7	677.62	8186.18

이처럼 ANOVA를 통해 선별된 특징을 이용하여 계층적인 SVM 트리를 구성함으로써 다중클래스 분류문제를 효율적으로 다룰 수 있다. 다음 그림 6은 4가지 진동신호를 분류하기 위해 본 논문에서 구성된 SVM 트리를 보여주고 있다.

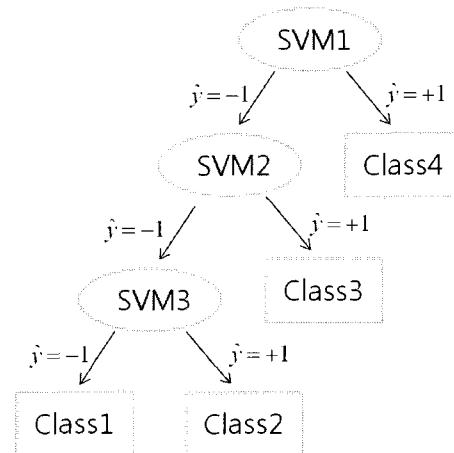


그림 6. 다중클래스 분류를 위한 SVM 트리

Figure 6. SVM tree for multi-class classification

그림에서 보는 바와 같이 SVM1은 클래스 4에 해당되는 패턴을 분류하는 데 이용된다. 이를 위해서는 특징벡터  $s(d_1)$ 과  $\bar{x}(d_1)$ 을 이용하는 것이 가장 바람직한 것으로 나타났다. 그림 7을 보면 클래스 4가 나머지 클래스로부터 어떻게 분리되는지를 파악할 수 있다. 다음 단계에서, 나머지 패턴의 학습은 SVM2에서 이루어진다. 여기서도 동일한 특징 벡터  $s(d_1)$ 과  $\bar{x}(d_1)$ 이 이용되는 데 그림 7에서 보는 바와 같이 클래스 3이 분리되고 있음을 알 수 있다. 마지막으로, SVM3은 클래스 1과 클래스 2를 분류하는 역할을 한다. 여기서는 특징벡터  $x_{\max}(d_3)$ 과  $s(d_2)$ 를 이용할 때 그림 7에서 보는 바와 같이 가장 분리가 잘 되는 것으로 나타났다.

제안된 SVM 트리의 분류성능을 알아보기 위해 그림 3에서 이용한 것과 동일한 Data를 생성시켜 수치실험을 수행한 결과 100%에 가까운 판별력을 갖는 것으로 나타났다. 이 실험은 4-fold 교차검증으로 이루어졌으며 Gunn (1998)이 제공한 Matlab Toolbox를 이용하였다.

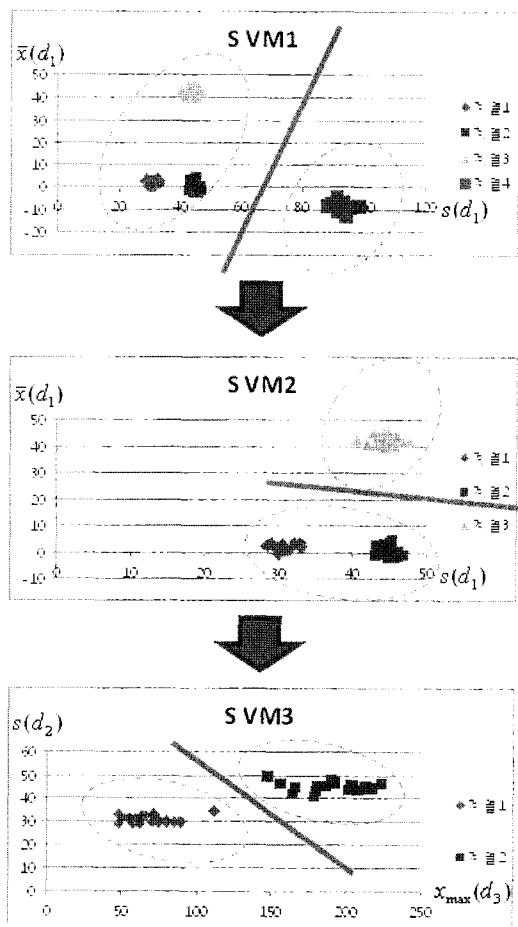


그림 7. SVM 트리에서 특징벡터의 순차적 적용

Figure 7. Sequential Selection of Feature Vectors in the SVM Tree

#### 4. 결 론

본 논문에서는 진동신호의 다중클래스 분류를 위한 트리 형태의 SVM 앙상블(Ensemble)을 제안하였다. 웨이블릿 영역에서 얻어진 통계적 특징 중 판별에 유의한 것 만을 둘러싸고 선별하기 위해 통계적인 분석방법인 ANOVA를 적용하였다. 선별된 특징벡터에 의한 계층적 학습으로 구성된 SVM 트리는 보다 개선된 성능을 갖는 것으로 수치실험을 통해 확인되었다. 또한 SVM에 따라 특징벡터를 개별적으로 추가할 수 있으므로 분류결과에 이상이 발생할 때에도 효율적인 대처가 가능할 것으로 전망된다.

#### 참 고 문 헌

- [1] V. Sugumaran, V. Muralidharan, and K. I. Ramachandran, "Feature Selection using Decision Tree and Classification through Proximal Support Vector Machine for Fault Diagnosis of Roller Bearing," *Mechanical Systems and Signal Processing*, Vol. 21, pp. 930-942, 2007.

- [2] V. Sugumaran, G. R. Sabareesh, and K. I. Ramachandran, "Fault Diagnostics of Roller Bearing using Kernel based Neighborhood Score Multi-class Support Vector Machine," *Expert Systems with Applications*, Vol. 34, pp. 3090-3098, 2008.
- [3] V. Sugumaran and K. I. Ramachandran, "Automatic Rule Learning using Decision Tree for Fuzzy Classifier in Fault Diagnosis of Roller Bearing," *Mechanical Systems and Signal Processing*, Vol. 21, pp. 2237-2247, 2007.
- [4] R. Yan and R. X. Gao, "An Efficient Approach to Machine Health Diagnosis based on Harmonic Wavelet Packet Transform," *Robotics and Computer-Integrated Manufacturing*, Vol. 21, pp. 291-301, 2005.
- [5] Q. Hu, Z. He, Z. Zhang, and Y. Zi, "Fault Diagnosis of Rotating Machinery base on Improved Wavelet Packet Transform and SVMs Ensemble," *Mechanical Systems and Signal Processing*, Vol. 21, pp. 688-705, 2007.
- [6] J. Rafiee, F. Arvani, A. Harifi, and M. H. Sadeghi, "Intelligent Condition Monitoring of a Gearbox using Artificial Neural Network," *Mechanical Systems and Signal Processing*, Vol. 21, pp. 1746-1754, 2007.
- [7] V. N. Vapnik, *Statistical Learning Theory*, Wiley, New York, 1988.
- [8] S. R. Gunn, "Support Vector Machines for Classification and Regression," Technical Report, University of Southampton, 1998.
- [9] 박성현, *현대실험계획법*, 민영사, 2003.

#### 저 자 소 개



김성준(Kim, Seong Jun)  
 1989년 : 연세대학교 응용통계학과 학사.  
 1991년 : 카이스트 산업공학과 석사.  
 1995년 : 카이스트 산업공학과 박사.  
 현재 : 강릉대학교 산업공학과 교수.

관심분야 : 지능정보, 통계학습, 품질경영

Phone : 033-640-2375

Fax : 033-640-2244

E-mail : sjkim@kangnung.ac.kr