

SVM을 이용한 웨이블릿기반 프로파일분류에 관한 연구

A Wavelet-based Profile Classification using Support Vector Machine

김성준
Seong-Jun Kim

강릉대학교 산업시스템공학과

요 약

베어링은 각종 설비에서 활용되는 중요한 기계요소 중 하나이다. 설비고장의 상당수는 베어링의 결함이나 파손에 기인하고 있다. 따라서 베어링에 대한 온라인모니터링기술은 설비의 정지를 예방하고 손실을 줄이는 데 필수적이다. 본 논문은 진동신호를 이용하여 베어링의 상태를 예측하기 위한 온라인모니터링에 대해 연구한다. 프로파일로 주어지는 진동신호는 이산웨이블릿변환을 통해 분석되고, 분해수준별 웨이블릿계수로부터 얻은 통계적 특징 중 유의한 것을 선별하고자 분산분석 (ANOVA)을 이용한다. 선별된 특징벡터는 Support Vector Machine (SVM)의 입력이 되는 데, 본 논문에서는 다중클래스 분류문제를 다루기 위한 계층적 SVM 네트워크를 제안한다.

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

1. 서 론

산업현장에서 각종 설비의 실시간 모니터링은 품질 및 생산성 측면에서 매우 중요한 이슈이다. 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. 스크래치, 크랙, 변형 등 베어링의 결함은 피로, 노후화, 하중의 변동, 운전조건외 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 결함패턴을 분류하는 방법을 연구하였다. 이 때 진동신호로부터 시간영역의 특징을 추출하기 위한 방안으로서 평균 (Mean), 표준편차 (Standard Deviation), 중위수 (Median), 범위 (Range), 왜도 (Skewness), 첨도 (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 같이 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.

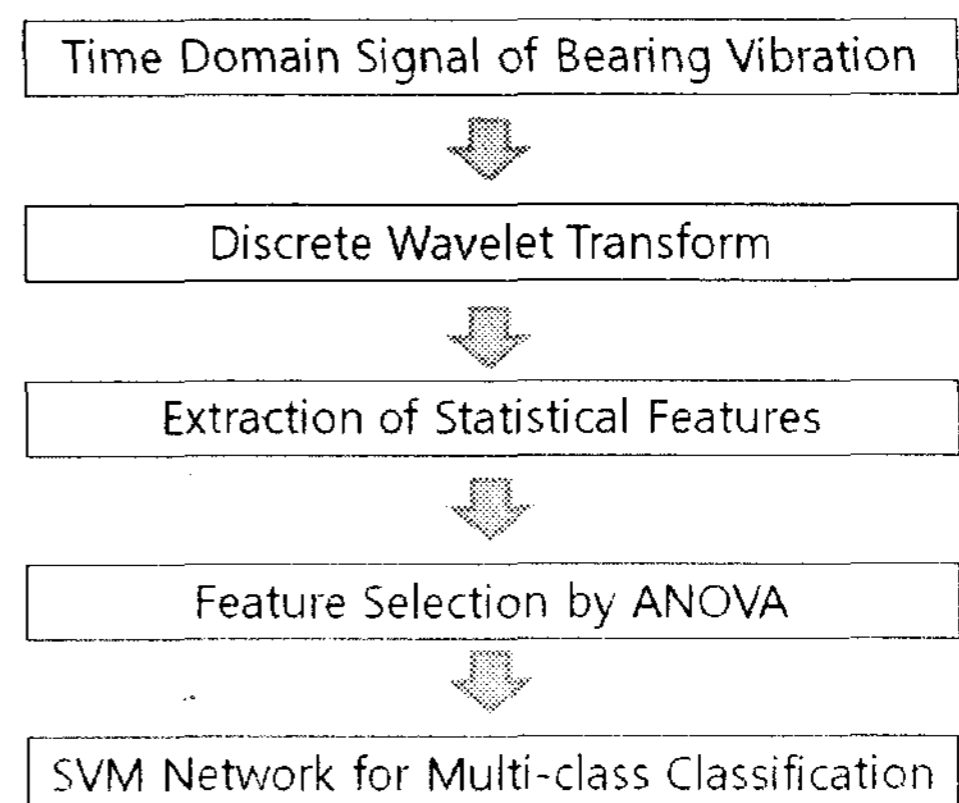


그림 1. 온라인모니터링을 위한 웨이블릿기반 SVM
Figure 1. SVM for online monitoring proposed in the present study

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

2. 진동프로파일 특징추출

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

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

(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

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

(e) Skewness

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

(f) Kurtosis

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

(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.

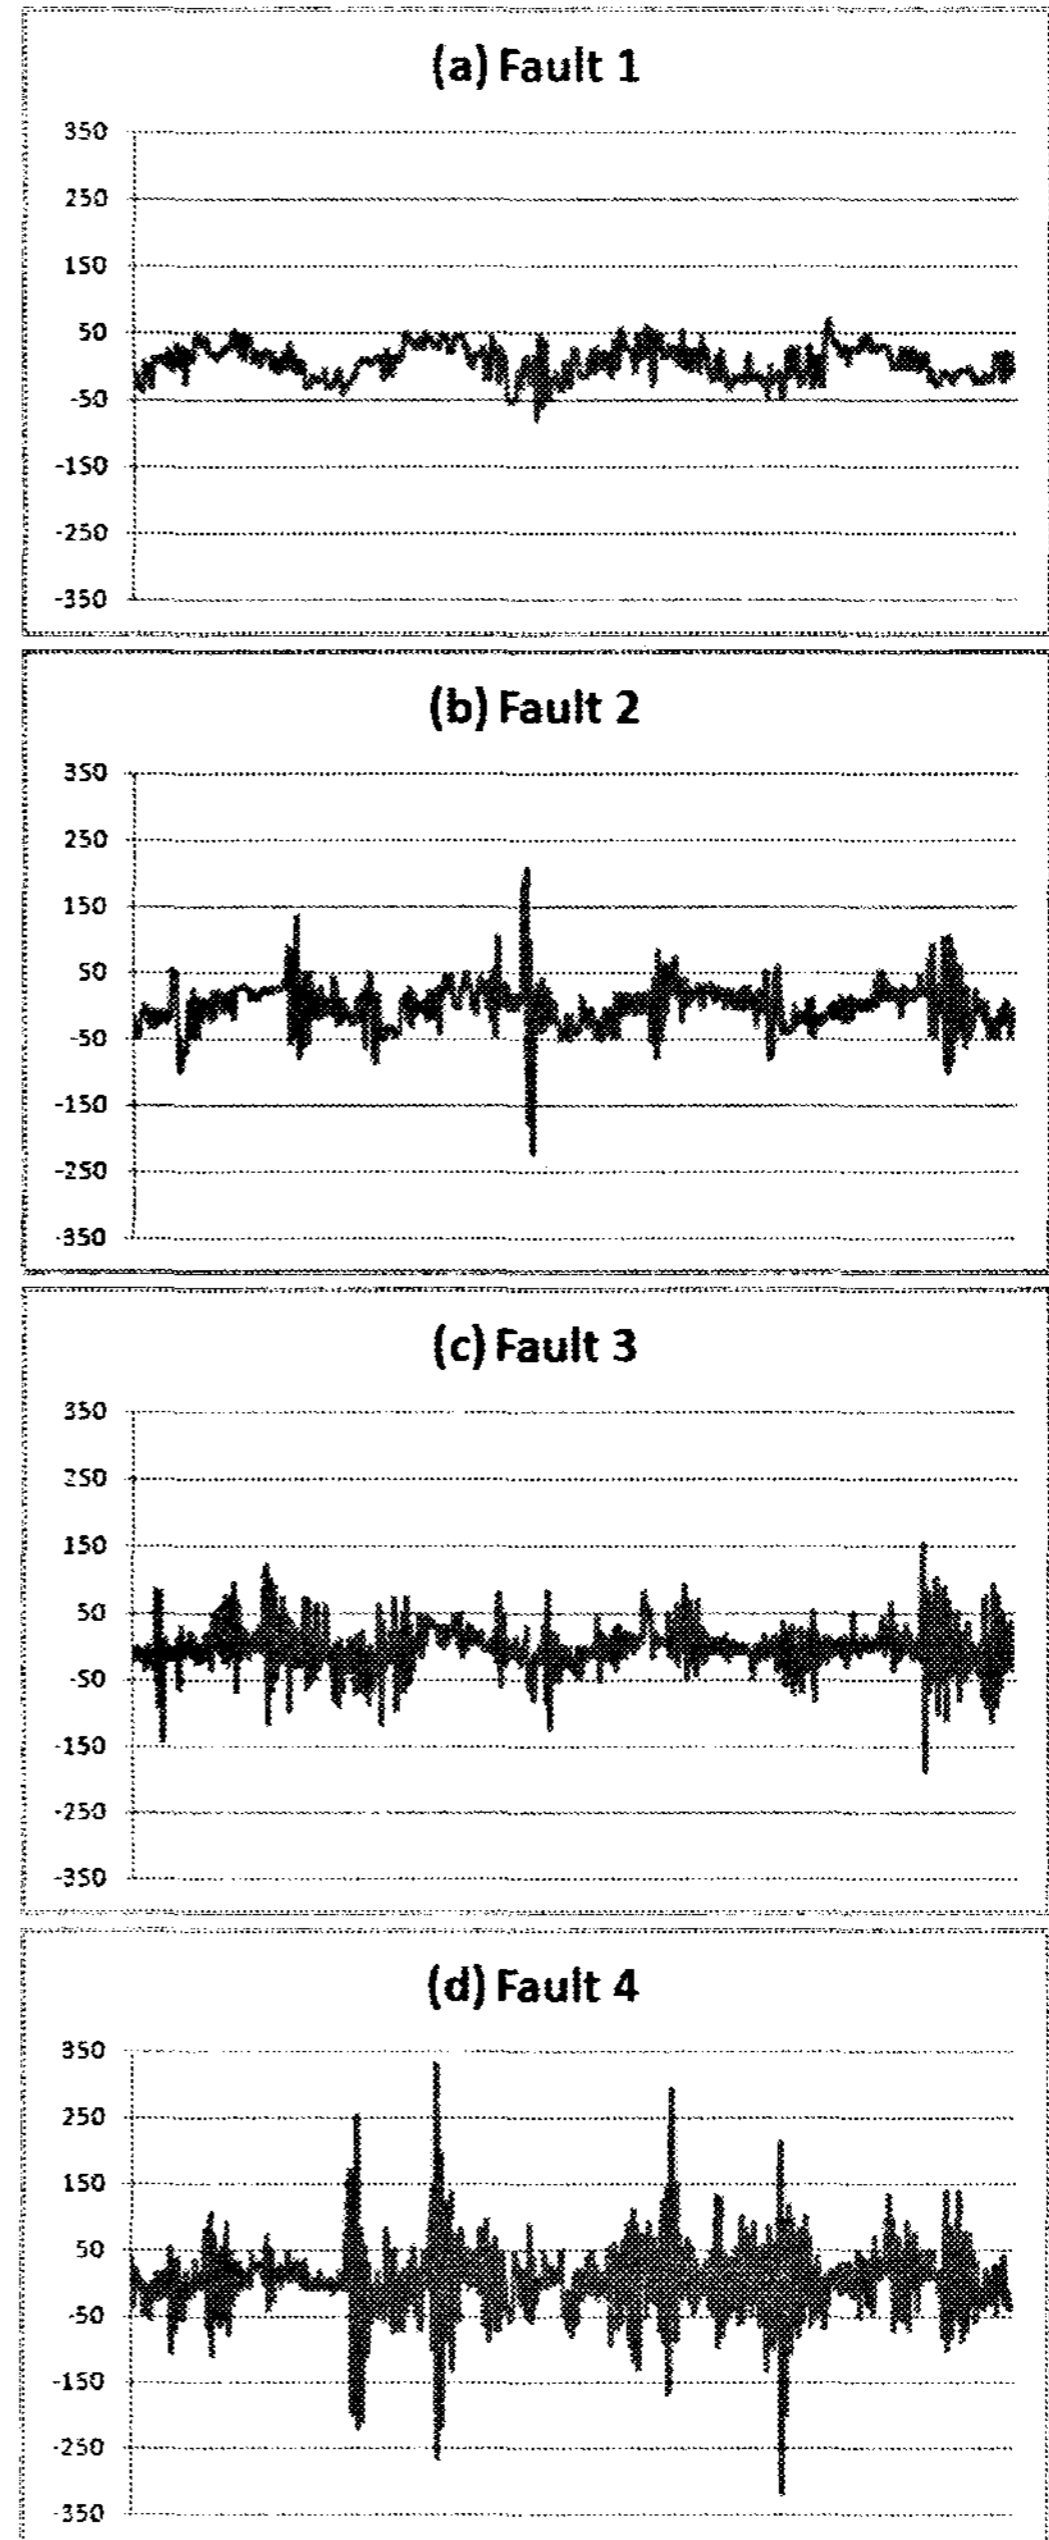


그림 2. 베어링 결함모드에 따른 진동신호 [1-3]
Figure 2. Vibration signals from the fault bearing

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 많은 연구에서 통계적 특징추출방법이 채택되고 있으나 패턴분류의 적합성에 대해서는 좀 더 면밀한 검토가 필요한 전망이다. 왜냐 하면 통계적 특징은 노이즈의 크기에 민감하게 반응하기 때문이다. 예를 들어, 그

림 2의 진동신호를 Baseline으로 하고 여기에 Gaussian Noise를 가미시켜 Simulated Signal을 생성한 후 통계적 특징추출을 수행한 결과의 일부가 다음 그림 3에 나타나 있다.

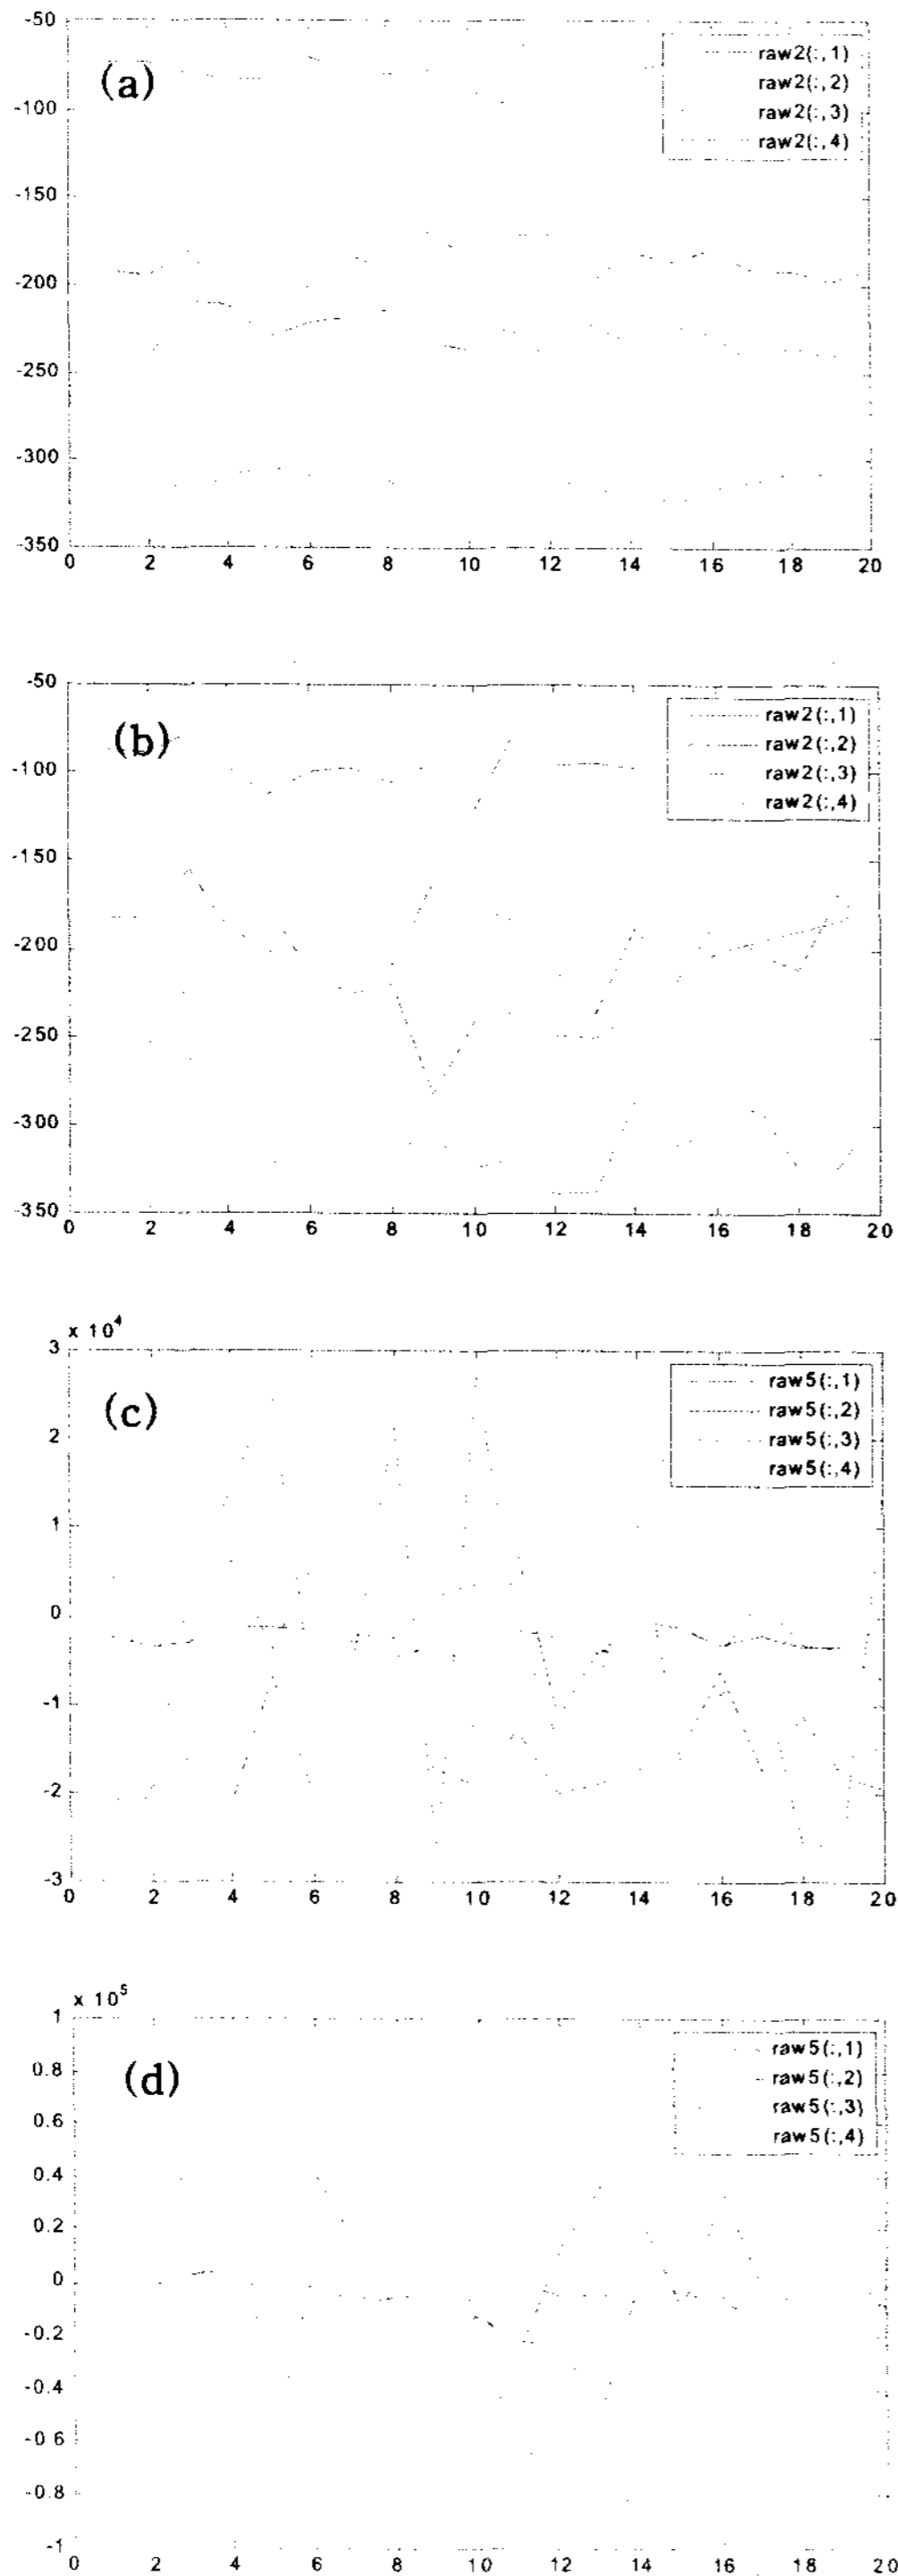


그림 3. 노이즈에 따른 통계적 특징추출
Figure 3. Statistical feature extractions by noise

그림 3은 σ 의 크기에 따른 진동신호의 Minimum value와 Skewness 계산결과를 도시한 것으로 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. 그림에서 알 수 있듯이 노이즈가 클수록 4가지 진동신호패턴에 대한 통계적 특징의 판별력은 저하되고 있다.

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 데이터마이닝과 패턴인식 분야에서 분류문제를 다루는 데 널리 활용되고 있다. 학습 데이터셋을 $D = \{(x_i, y_i) | i = 1, 2, \dots, n\}$ 이라고 하자. 단 x_i 는 m 차원의 특징벡터를 의미하고 클래스 $y_i \in \{-1, +1\}$ 를 갖는다. SVM의 기본 아이디어는 클래스를 양분할 수 있는 초평면 (Hyperplane)을 찾는 것으로, 이는 다음 그림의 Margin을 최대화하는 문제로 다루어진다.

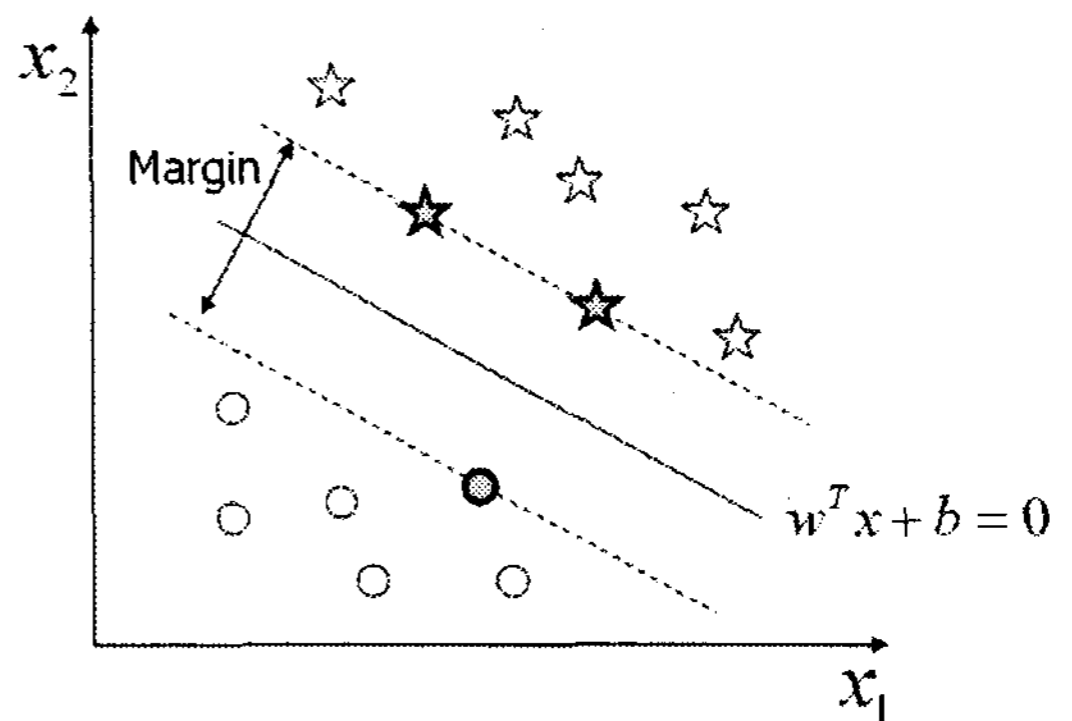


그림 4. SVM에 의한 분류
Figure 4. Classification by SVM

Support Vector란 마진의 경계에 위치한 특징벡터를 말하며 그림 4에서는 굵게 표시되어 있다. 하지만 분류문제는 이처럼 선형으로 분리되지 않는 것이 대부분이므로 특징벡터를 선형분리가 가능한 보다 높은 차원으로 변환해야 한다. 이 때 변환 $\phi(x)$ 의 내적으로 정의되는 함수인 $K(x, x_i) = \phi(x)^T \phi(x_i)$ 를 커널 (Kernel)이라고 부른다. SVM의 장점은 개별 변환결과와 관계없이 커널만으로 최적 분류가 가능하다는 데 있다. Polynomial Mapping, Gaussian Radial Basis Function, Multi-layer Perceptron 등이 대표적인 커널로 사용된다. 신경회로망 등 대부분의 방법은 Empirical Risk Minimization에 기초하고 있는 반면, SVM은 Structural Risk Minimization에 기초한다. 이런 연유로, SVM 쪽이 적은 학습데이터로도 더 나은 일반화능력을 보여줄 수 있다[8].

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 우선 분해수준이 4인 Haar 웨이블릿을 이용한다.

각 분해수준에서 얻어진 통계적 특징을 모두 사용하는 것은 비효율적이므로 분해수준 별로 지배적 특징을 선별하는 것이 바람직하다. 이를 위한 방안으로 본 연구에서

는 ANOVA (Analysis of variance)를 이용하기로 한다. 원래 ANOVA는 조건 별로 평균값이 얼마나 변화하는지를 통계적으로 판단하는 방법이지만, 본 연구에서는 웨이블릿계수로 얻어진 특징추출값이 진동신호 패턴에 대해 얼마나 판별력이 큰지를 정량적으로 평가하기 위해 채용되었다.

3.3 다중클래스 분류를 위한 SVM 네트워크

먼저 웨이블릿변환과 ANOVA에 의해 유의한 특징을 선별한 결과에 대해 살펴본다. 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 Sugumaran의 결과와는 달리 x_{min} 나 m_3 는 거의 효과가 없는 것으로 나타났다. 상세수준에서는 Standard deviation의 역할이 두드러진다. 이것은 특히 d_4, 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.

이처럼 ANOVA를 통해 선별된 특징을 이용하여 계층적인 SVM 네트워크를 구성함으로써 다중클래스 분류문제를 효율적으로 다룰 수 있다. 다음 그림 5는 4가지 진동신호를 분류하기 위해 본 논문에서 구성된 SVM 네트워크를 보여주고 있다.




그림 5. 다중클래스 분류를 위한 SVM 네트워크
Figure 5. SVM Network for multi-class classification

그림에서 보는 바와 같이 3개의 SVM이 포함되어 있다. 추가적인 분석 결과, SVM1의 학습에는 특징벡터 $s(d_1)$ 과 $\bar{x}(d_1)$ 을 이용하는 것이 가장 바람직한 것으로 나타났다. SVM1의 목적은 클래스 4에 해당되는 패턴을 분류해내는 데 있다. 나머지 패턴의 학습은 SVM2에서 이루어진다. 여기서도 같은 특징벡터 $s(d_1)$ 과 $\bar{x}(d_1)$ 가 이용된다. SVM2를 통해 클래스 3 패턴이 분류되고 나면 마지막으로 SVM3이 클래스 1과 2의 패턴을 분류하게 되는 것이다. SVM3에서는 특징벡터 $x_{max}(d_3)$ 와 $s(d_2)$ 를 이용하는 것이 가장 좋은 결과를 가져다 주었다.

제안된 SVM 네트워크의 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[8]

이 제공하는 Matlab Toolbox를 이용하였다.

4. 결론

본 논문에서는 진동신호의 다중클래스 분류를 위한 SVM 네트워크를 제안하였다. 웨이블릿영역에서 얻어진 통계적 특징 중 판별에 유의한 것만을 능률적으로 선별하기 위해 통계적인 분석방법인 ANOVA를 적용하였다. 선별된 특징벡터에 의한 계층적 학습으로 구성된 SVM 네트워크는 보다 개선된 성능을 갖는 것으로 수치실험을 통해 확인되었다. 또한 SVM에 따라 특징벡터를 개별적으로 추가할 수 있으므로 분류결과에 이상이 발생할 때에도 효율적인 대처가 가능하다.

사 의

본 논문은 2007년도 정부재원 (교육인적자원부 학술연구조성사업비)으로 한국학술진흥재단의 지원을 받아 연구되었음(KRF-2007-000-D00545).

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.