

공학석사 학위논문

Support Vector Machine을 이용한  
회전기계의 상태 분류 및 결함 진단



이 논문을 공학석사 학위논문으로 제출함

2003년 12월

부경대학교 대학원

음향진동공학과

황 원 우

# 황원우의 공학석사 학위논문을 인준함

2003년 12월

주 심 공학박사 김 천 덕



위 원 공학박사 배 동 명



위 원 공학박사 양 보 석



# 목 차

Abstract	3
제 1장 서론	4
1.1 연구 배경	4
1.2 연구 내용	6
제 2장 Support Vector Machine	8
2.1 개요	8
2.2 Support Vector Machine	8
2.3 커널 함수	11
2.4 Sequence Minimize Optimization	15
2.4.1 Lagrange 승수 $\alpha_i$ 의 최적화 과정	15
2.4.2 한계값 $b$ 의 결정	18
2.5 Multi-class SVMs의 전략	19
2.5.1 One-against-all 기법	19
2.5.2 One-against-one 기법	20
제 3장 회전 기계의 결합 진동 특성	22
3.1 개요	22
3.2 불평형	22
3.3 정렬불량	24
3.4 공진	26
3.5 베어링 결합	27
제 4장 특징 추출	29
4.1 개요	29
4.2 특징 추출 파라미터	29
4.2.1 시간 영역	29
4.2.2 주파수 영역	34

4.2.3 Entropy 영역 .....	36
4.3 Wavelet 변환 .....	37
4.3.1 연속 wavelet 변환 .....	39
4.3.2 이산 wavelet 변환 .....	40
제 5장 적용 예 .....	41
5.1 냉장고용 소형 왕복동 압축기의 상태 분류 .....	41
5.1.1 상태 분류 시스템 .....	41
5.1.2 데이터 취득 .....	41
5.1.3 특징 추출 .....	44
5.1.4 시뮬레이션 결과 .....	46
5.2 회전기계의 결함 진단 .....	49
5.2.1 결함 진단 시스템 .....	50
5.2.2 실험 장치 및 데이터 취득 .....	51
5.2.3 특징 추출 .....	56
5.2.4 시뮬레이션 결과 .....	59
제 6장 결론 .....	64
참고문헌 .....	65
감사의 글 .....	68

# **Condition classification and fault diagnosis of rotating machinery using support vector machines**

**Won-Woo Hwang**

*Department of Interdisciplinary Program of  
Acoustics and Vibration, Graduate School  
Pukyong National University*

## **ABSTRACT**

Condition monitoring and fault diagnosis of rotating machinery has been received considerable attention, which can increase machinery availability and performance, reduce consequential damage, increase machine life, and reduce spare parts inventories and breakdown maintenance. Since engineers who have expert knowledge and experience are rare, the intelligent systems are necessary in the real world.

In this study, support vector machine (SVM) algorithm is applied for the intelligent condition classification and fault diagnosis system of rotating machinery. Vibration signals are selected as system input due to its easy measurement, high accuracy and reliability. The discrete wavelet transform and feature extraction are used as preprocessing. To detect multiple faults in rotating machinery, the strategies of multi classification with kernel functions of SVM are utilized.

The test results were satisfied and achieved good success classification rate comparing with existing artificial neural networks, such as SOM, LVQ and RBF. Therefore, SVM is promising and suitable for real application.

# 1. 서론

## 1.1 연구 배경

최근 산업의 발전과 기술의 진보에 따라 각종 산업용 회전기계는 대용량, 고속화, 고 하중으로 되고 있고, 이는 가혹한 운전조건으로 작용하여 많은 스트레스를 기계에 부가하게 된다. 제품의 생산 효율, 품질의 중요성과 아울러 안정적인 기능 유지, 보수 및 진단에 대한 인식이 높아지고 있으며 이미 커다란 경제적인 영역을 형성하고 있다. 특히, 회전기계는 발전플랜트 등 각종 산업 현장에서 광범위하게 사용되고 있으며 중요한 역할을 수행하기 때문에, 이상이 발생했을 때 즉각적인 고장원인의 추정과 그에 대한 대응책이 요구된다.

회전기계에서 발생하는 이상이나 고장시의 진동신호는 여러 상태변화의 결과이며, 그 관계가 매우 다양하고 복잡하기 때문에 원인을 추정하는 데에는 매우 전문적인 지식과 오랜 경험이 필요하다. 그러므로 시스템의 고성능화, 복잡화 및 전문가의 부족으로 인하여 진단의 자동화를 도모하고자 할 때에는 진동 원인과 발생하는 현상과의 관계를 잘 표현할 수 있는 기법이 요구되며 이에 대한 연구가 여러 방면에서 이루어지고 있다.

컴퓨터를 이용한 지능적인 고장진단은 크게 지식기반진단(knowledge based diagnostics)과 거동기반진단(behavior based diagnostics)으로 나눌 수 있다. 지식기반 진단은 다양한 기계에 대하여 고장 진동 특성을 분석하여 지식 베이스를 구성하고 이 지식 베이스를 기초로 실제 기계의 이상유무를 판단하는 것이다. 대표적인 예로 사례기반 추론시스템(Case-Based Reasoning, CBR)이 있다. 거동기반진단은 특정한 기계의 실제 상태에서 출발하여 운전상태의 변화로부터 고장을 진단하는 것으로써 현대 신경 생리학과 심리학을 기반으로 인간의 대뇌

신경세포의 구조특성을 모방하여 만든 비선형 네트워크 시스템인 인공신경망 (artificial neural network) 등이 있다. 대표적인 인공 신경망으로는 Hopfield, Rumelhart, 다층퍼셉트론(multi-layer perceptron), 적응공진이론(adaptive resonance theory, ART), Boltzmann machine, 자기조직화특징지도(self-organizing feature map, SOFM), 학습벡터 양자화(learning vector quantization, LVQ), radial basis function (RBF) 신경망 등이 있다. 이러한 신경망은 음성식별, 문자 식별, 목표인식, 화상식별 등 패턴 인식분야에서 널리 응용되고 있다.

패턴 인식 문제라는 것은 주어진 데이터로부터 특정 정보를 자동적으로 찾아내는 문제(detection)와 주어진 데이터를 2 개 이상의 그룹으로 분리하여 특성을 파악하는 문제(classification)로 크게 나뉘어 진다. 이러한 패턴인식 문제는 의료 이미지 정보의 자동해석(MRI, NMI, X-ray 등), 자동 생산시스템의 품질검사, 컴퓨터 음성인식, 물질 분류, 지질 변화예측, 지문, 홍채, 문자 인식 등의 다양한 응용분야를 가지고 있다.

인공 신경망을 이용한 패턴 인식문제를 해결하려 할 경우, 매우 복잡한 입력 패턴의 분포를 추정하기가 어려우므로 학습단계에서 많은 양의 학습 데이터가 필요하게 된다. 또한 국부 최소값(local minimum)을 피하기 위한 초기화 작업이 거의 경험적으로 이루어지며, 수렴속도의 지연 그리고 근사화 및 수렴율에 영향을 미치는 커널(kernel) 함수의 선택 등이 여전히 어려운 문제로 남아 있다. 또한 수렴성을 증명하는 문제도 풀어야 할 과제로 남아 있다.[1]

이러한 문제들을 해결하기 위한 방안으로 1995 년 Vapnik 에 의해 Universal feed forward 네트워크의 한 종류인 Support Vector Machine(SVM)이 제안되었고, 본 연구에서는 회전기계에서 발생할 수 있는 결함을 진단하기 위해 SVM 알고리즘을 이용한 상태 감시 및 결함진단 시스템을 제안하고, 인위적인 결함을 부여할 수 있는 실험 장치로부터 취득한 진동신호를 이용하여 제안된 알고리즘의 유용성을 확인하였다.

## 1.2 연구 내용

본 연구에서는 SVM을 거동기반진단에 응용하여 회전기계의 상태감시 및 고장 진단 알고리즘을 구성하고 특성을 분석하였으며 회전기계에 인위적으로 결함을 부여 할 수 실험장치를 통하여 분류화 성능을 검토하였다.

이를 위해 먼저 제 2장에서는 SVM에 대한 일반적인 수학적 접근 방법에 대해 설명하였다. 이 알고리즘은 상태 감시 및 결함 진단을 수행하는 핵심 알고리즘이다. 그리고 SVM의 학습과정을 수학적으로 제시하였다. Sequence minimize optimization(SMO) 알고리즘은 전체 QP(quadratic programming) 문제를 해결하기 위한 방법으로 전체를 가능한 작은 크기의 QP 문제로 분해하여 해결한다. 이는 해석적인 방법으로 풀기 때문에 내부 루프로서 시간 소비적인 수치적 QP 최적화를 수행하지 않는다. 또한 필요한 메모리의 크기도 학습 데이터의 크기에 따라 선형적으로 달라진다. 따라서 매우 방대한 양의 학습데이터도 다룰 수 있는 장점을 가지고 있다. 또한 실제적인 많은 문제가 비선형적인 특성을 가지고 있다. 그래서 비선형적 분리를 위하여 입력 공간에서 고차원 특징 공간으로의 변환을 위한 커널 함수를 사용하였다.

그리고 이 장의 마지막으로 이진 분류를 수행하는 SVM을 여러 실제 클래스(class)를 가지는 결함 진단에 적용하기 위한 방법으로 이진 분류의 조합에 대한 전략을 이용한 Multi-class 학습전략을 설명하였다.

제 3장에서는 일반적인 회전기계에서 빈번히 발생하는 주요 결함에 대한 진동 특징들을 검토하였다.

제 4장에서는 SVM의 훈련(training) 및 테스트(testing) 과정에 사용되는 입력 파라미터인 특징 파라미터 대한 기본적인 이론과 특징 추출 방법에 대하여 설명하였다. 상태감시 및 결함진단에 있어서 특징 파라미터는 매우 중요한 역할을 한다. 그래서 특징 파라미터의 선정에 있어 기계의 결함에 대해 가능한

많은 정보를 포함하는 파라미터를 사용하여야 한다. 또한 적절한 신호처리 기법의 도입이 필요하다. 본 연구에서는 회전기계의 정상 상태와 각종 결함 상태의 진동특징을 추출하기 위하여 통계적인 방법을 사용하였으며 신호 처리 기법들로 웨이블릿 변환(wavelet transform)을 이용하였다.

제 5장에서는 앞에서 제시한 이론들을 토대로 하여 상태감시 및 결함진단 알고리즘을 제안하고, 그 유용성을 평가하기 위해 냉장고용 소형 압축기의 상태분류와 회전기계의 결함진단에 적용하였다.

제 6장에서는 본 연구의 주요 결론을 요약하였다.

## 2. Support Vector Machine (SVM)

### 2.1 개요<sup>[1]</sup>

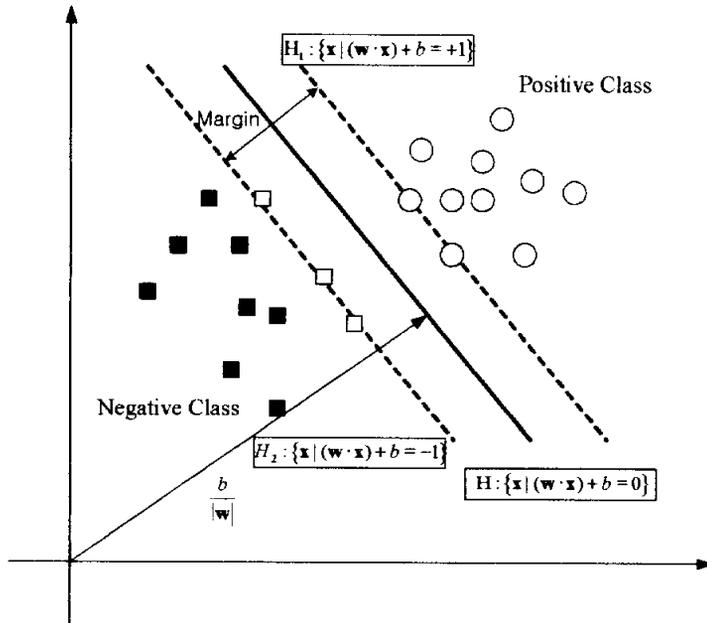
1995년 Vapnik에 의해 제안된 SVM은 인공 신경망이 가진 몇몇의 단점을 극복하였으며, 또한 명료한 이론적 근거에 기반을 두고 있다. 이는 입력으로부터 어떠한 학습 방법을 이용하는가에 대한 직관적인 해석을 제공해 준다. 즉, 간단하고 명료한 알고리즘을 통하여 학습을 성공적으로 수행하는데 영향을 미치는 요소들을 규명할 수 있다. 또한 실제 응용 문제에서 높은 인식 성능을 나타낸다. SVM 기법은 실제 응용에 있어 복잡한 구조의 패턴을 인식하기 위해 입력 공간의 비선형적인 높은 차수를 특징 공간에서 선형적으로 투영하여 해석할 수 있도록 하며 각 특징 사이의 최적의 초평면(hyperplane)을 제시한다. 이러한 특성으로 인해 현재 이 알고리즘은 비선형 패턴인식 문제나 함수 회귀 문제, 데이터 마이닝, 컴퓨터 비전, 인공지능, 예측, 의료 진단 등의 다양한 분야에서 활용되고 있으며 매우 활발하게 연구가 진행되고 있다.

### 2.2 Support Vector Machine<sup>[2-4]</sup>

기본적인 SVM은 이진 분류 문제에 이용되며, 초평면을 중심으로 한쪽은 Positive class, 다른 한쪽은 Negative class로 나눈다. 두 데이터 집합의 경계가 되는 초평면은 식 (2.1)과 같이 정의된다.

$$\begin{aligned} H: (\mathbf{w} \cdot \mathbf{x}) + b &= 0 \\ \mathbf{w} \in R^N, b \in R \end{aligned} \tag{2.1}$$

여기서,  $\mathbf{w}$  는 두 데이터 집합의 경계가 되는 가중치벡터,  $\mathbf{x}$  는  $N$  차원의 입력벡터,  $b$  는 한계값(threshold value)이다.



**Fig. 2.1** Binary classification of dataset by SVM

Fig. 2.1 은 다른 두 데이터 집합이 경계가 되는 초평면  $H$  에 의해 나누어짐을 보이고 있다. SVM 은 경계와 각 클래스에 속한 가장 인접한 데이터와의 거리(margin)가 최대가 되게 한다. 경계와 가장 인접한 회색의 원과 사각형 데이터 점을 support vector (SV) 라 하며, 이 SV 에는 두 클래스를 구분할 수 있는 모든 정보들이 포함되어 있기 때문에 이를 제외한 나머지 데이터는 필요 없게 되어 폐기된다. 따라서 데이터의 overfitting 과 테스트 시간이 상대적으로 모든 데이터를 사용하는 다른 알고리즘에 비하여 빠르게 된다. 새로운 데이터에 대한 결정함수(decision function)는 식 (2.2)와 같다.

$$f(\mathbf{x}) = \text{sign}((\mathbf{w} \cdot \mathbf{x}) + b) \tag{2.2}$$

두 초평면  $H_1$  과  $H_2$  사이의 거리를 구하면 식 (2.3)과 같으며, 이 값이 최대가 되어야 한다.

$$\text{margin} = \frac{2}{\|\mathbf{w}\|} \quad (2.3)$$

식 (2.2)와 (2.3)을 정리하여 나타내면, 식 (2.4)와 같다.

$$\begin{aligned} &\text{Minimize} \\ &\frac{1}{2}\|\mathbf{w}\|^2 \\ &\text{subject to} \\ &y_i((\mathbf{w} \cdot \mathbf{x}_i) + b) \geq 1, y_i = \{+1 \text{ or } -1\} \end{aligned} \quad (2.4)$$

식 (2.4)를 풀기 위하여 Lagrange 승수(multipliers)의  $\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_N \geq 0$  개념을 도입하면, Lagrangian 은 식 (2.5)와 같이 된다.

$$L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2}\|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i y_i (\mathbf{w} \cdot \mathbf{x}_i + b) + \sum_{i=1}^N \alpha_i \quad (2.5)$$

여기서,  $\frac{\partial L}{\partial \mathbf{w}} = 0, \frac{\partial L}{\partial b} = 0$  이고, 이는 각각 다음과 같이 유도된다.

$$\begin{aligned} \mathbf{w} &= \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i \\ \sum_{i=1}^N \alpha_i y_i &= 0 \end{aligned} \quad (2.6)$$

식 (2.6)을 식 (2.5)에 대입하여 정리하면,

Maximize

$$L_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \quad (2.7)$$

subject to  $\alpha_i \geq 0, i=1,2,\dots,N$

$$\sum_{i=1}^N \alpha_i y_i = 0$$

식 (2.7)을 통하여  $\alpha_i$  를 구할 수 있으며, 이  $\alpha_i$  를 식 (2.6)에 대입하여  $\mathbf{w}$  를 구할 수 있다. 식 (2.6)을 사용하여 결정 함수인 식 (2.2)를 재정의하면 식 (2.8)과 같다.

$$f(\mathbf{x}) = \text{sign} \left( \sum_{i=1}^N \alpha_i y_i (\mathbf{x}_i \cdot \mathbf{x}) + b \right) \quad (2.8)$$

따라서, 이제 한계값  $b$  를 구하게 되면, 새로운 입력 데이터  $\mathbf{x}$  를 분류할 수 있게 된다. 여기서  $b$  는 SVM 의 학습 알고리즘인 SMO 에서 구해진다.

### 2.3 커널 함수 [1], [3-6]

SVM 은 초평면이라 정의되는 선형 함수에 의해서 분류를 수행한다. 그러나 대부분의 복잡한 실제 응용문제에서 입력 벡터들은 입력공간 내에 비선형적으로 분포하게 된다. 그래서 선형 함수에 의해 분류의 수행에는 한계를 가지게 되며, 이를 극복할 대안으로  $N$  차원의 입력 공간의 데이터들을 고차원의 특징 공간( $Q$  차원)으로 사상(mapping)함으로써 고차원의 특징 공간에서 선형적으로 분리할 수 있다. 식 (2.9)는 사상을 위한 변환함수를 나타낸다. 그러나 일반적으로 이 사상함수는 알려져 있지 않다.

$$\mathbf{x} = (x_1, x_2, \dots, x_n) \rightarrow \Phi(\mathbf{x}) = (\Phi_1(\mathbf{x}), \Phi_2(\mathbf{x}), \dots, \Phi_Q(\mathbf{x})) \quad (2.9)$$

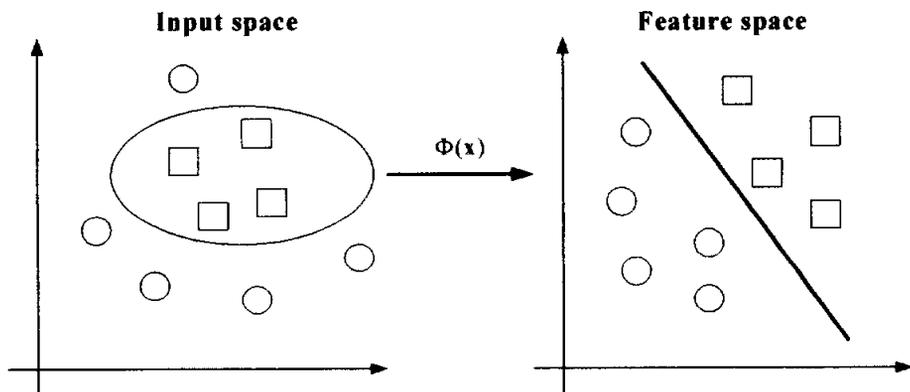


Fig. 2.2 Transformation to linear feature space from nonlinear input space

식 (2.9)를 결정 함수인 식 (2.8)에 대입하면 다음과 같다.

$$f(\mathbf{x}) = \text{sign} \left( \sum_{i=1}^N \alpha_i y_i (\Phi(\mathbf{x}) \cdot \Phi(\mathbf{x}_i)) + b \right) \quad (2.10)$$

여기서, 내적  $(\Phi(\mathbf{x}) \cdot \Phi(\mathbf{x}_i))$ 를 특징공간 내에서 직접적으로 계산할 수 있는 커널함수  $K(\mathbf{x}, \mathbf{x}_i) = \Phi(\mathbf{x}) \cdot \Phi(\mathbf{x}_i)$ 로 대체하면 식 (2.11)과 같이 된다.

$$f(\mathbf{x}) = \text{sign} \left( \sum_{i=1}^N \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \right) \quad (2.11)$$

따라서, 식 (2.11)을 통하여 SVM 이 비선형적인 입력 공간을 선형적인 특징 공간으로 변환하여 분류할 수 있다.

지금까지의 연구되어진 커널함수로는 Linear, Polynomial, Sigmoid, Dirichlet, Laplacian RBF 및 Gaussian RBF 등이 있다. 각각의 정의식은 Table 2.1 과 같으며, Fig. 2.3 은 커널 함수들의 형태를 보여주고 있다.

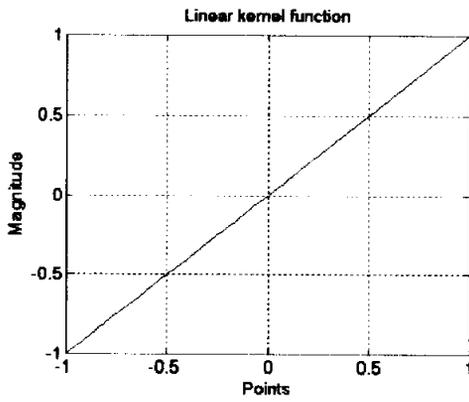
현재, Gaussian RBF 커널 함수가 가장 많이 사용되고 있으며, 또한 실제 분류화 문제에서 좋은 성능을 보여주고 있다.<sup>[6,7]</sup> Gaussian RBF 커널 함수의 미지

의 파라미터인 커널 폭(kernel width)  $\sigma$  값은 SVM의 일반화 성능에 지대한 영향을 미친다. 이 파라미터의 값을 결정함에 있어 아래의 특성을 고려하여야 한다.<sup>18)</sup>

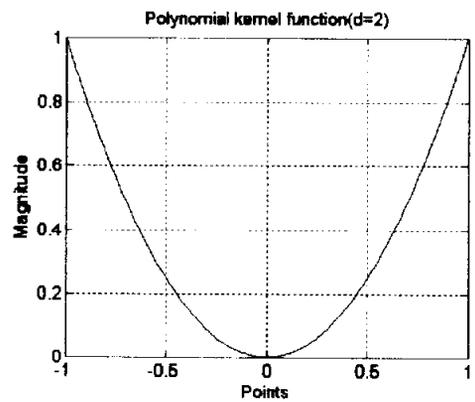
- 1)  $\sigma$ 의 값이 너무 클 경우에는 모든 훈련 데이터의 각각이 하나의 데이터로 간주되며 그 결과 SVM은 미지의 데이터에 대해 어떤 새로운 데이터로 인식하지 못하기 때문에 분류의 성능이 현저히 떨어진다.
- 2)  $\sigma$ 의 값이 너무 작을 경우, 모든 훈련 데이터의 각각의 데이터가 support vector로 간주되어져 훈련 집합 내에서는 모두 분류가 되지만 새로운 미지의 데이터에 대해선 그들의 소속을 잘못 분류할 수가 있다.

**Table 2.1** Formulation of kernel function

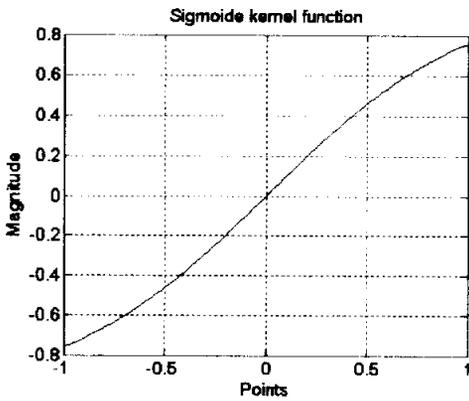
Kernel Function	Formulation
Linear	$K(\mathbf{x}, \mathbf{y}) = \mathbf{x} \cdot \mathbf{y}$
Polynomial	$K(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y} + 1)^d$
Sigmoid	$K(\mathbf{x}, \mathbf{y}) = \tanh(a \times \mathbf{x} \cdot \mathbf{y} / b + 2)$
Dirichlet	$K(\mathbf{x}, \mathbf{y}) = \{\sin(N + 0.5) \times (\mathbf{x} - \mathbf{y})\} / \{2 \times \sin((\mathbf{x} - \mathbf{y}) / 2)\}$
Laplacian RBF	$K(\mathbf{x}, \mathbf{y}) =  \mathbf{x} - \mathbf{y} $
Gaussian RBF	$K(\mathbf{x}, \mathbf{y}) = \exp\left\{-\left(\ \mathbf{x} - \mathbf{y}\ ^2 / 2\sigma^2\right)\right\}$



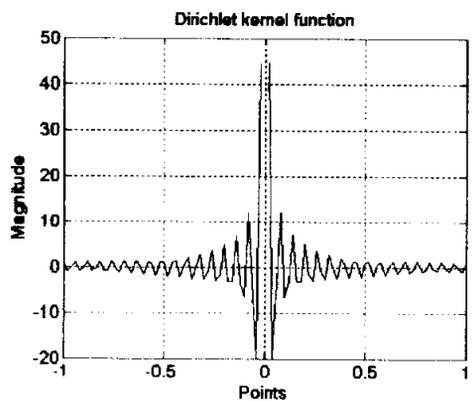
(a) Linear kernel function



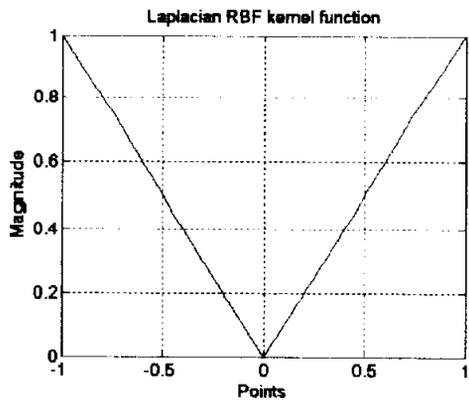
(b) Polynomial kernel function ( $d = 2$ )



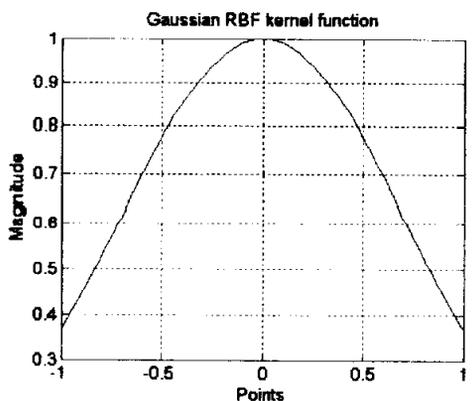
(c) Sigmoid kernel function



(d) Dirichlet kernel function



(e) Laplacian RBF kernel function



(f) Gaussian RBF kernel function

Fig. 2.3 The typical waveform of kernel functions

## 2.4 Sequence Minimize Optimization <sup>[3][10-11]</sup>

Sequence Minimize Optimization (SOM) 알고리즘은 SVM 을 학습시키기 위해, 기존의 분해법과 유사한 방법으로 가능한 가장 작은 크기의 Quadratic Programming (QP) 문제로 나누어서 전체 QP 최적화 문제를 풀게 된다. SMO 는 QP 문제를 해석적인 방법으로 풀기 때문에 내부 루프로서 시간 소비적인 수치적 QP 최적화를 행하지 않는다. 또한 필요한 메모리의 크기도 학습 데이터의 크기에 따라 선형적으로 달라진다. 따라서 매우 방대한 양의 학습 데이터도 다룰 수 있고, 또한 학습에 소요되는 시간은 SVM 의 결정 함수를 평가하는데 지배되기 때문에 선형 SVM 과 학습 데이터 양이 적은 경우에 적합하다.

### 2.4.1 Lagrange 승수 $\alpha_i$ 의 최적화 과정

SMO 알고리즘은 목적함수를 최대화 하는  $\alpha_i$  를 구하는데 있어 한번에 두개의  $\alpha_i$  값을 찾는다. 목적함수는 식 (2.12), 구속조건은 식 (2.13)과 같다.

$$L_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \quad (2.12)$$

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (2.13)$$

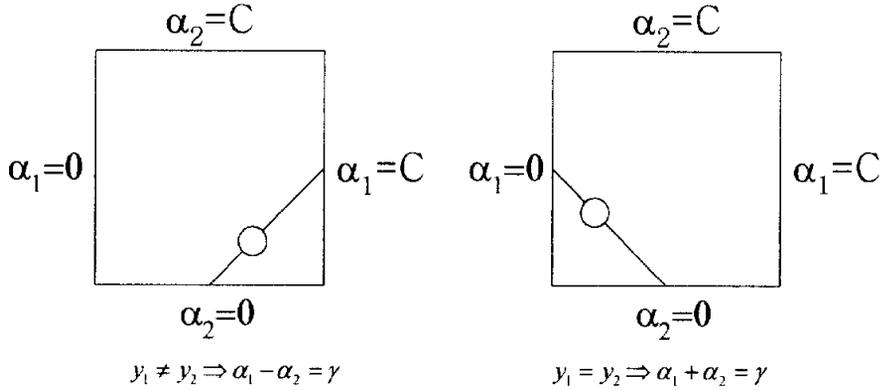
식 (2.13)의 조건을 이용하여  $\alpha_1$ ,  $\alpha_2$  값을 제외한 나머지  $\alpha$  값은 임의의 값으로 고정시킨다. 그러면 식 (2.13)을 다음과 같이 쓸 수 있다.

$$y_1 \alpha_1 + y_2 \alpha_2 = y_1 \alpha_1^{\text{old}} + y_2 \alpha_2^{\text{old}} = \text{const} \quad (2.14)$$

Fig. 2.4 는 식 (2.14)를 나타낸 것이다. 이는 경계구속을 나타내는 것으로  $\alpha_2$  의 경계값은 다음과 같이 된다.

$$\begin{cases} L = \max(0, \alpha_2^{\text{old}} - \alpha_1^{\text{old}}) \\ H = \min(C, C + \alpha_2^{\text{old}} - \alpha_1^{\text{old}}) \end{cases} \quad \text{if } y_1 \neq y_2$$

$$\begin{cases} L = \max(0, \alpha_1^{\text{old}} + \alpha_2^{\text{old}} - C) \\ H = \min(C, \alpha_1^{\text{old}} + \alpha_2^{\text{old}}) \end{cases} \quad \text{if } y_1 = y_2$$
(2.15)



**Fig. 2.4**  $y_1\alpha_1 + y_2\alpha_2 = y_1\alpha_1^{\text{old}} + y_2\alpha_2^{\text{old}} = \text{const.}$

목적함수를 풀어 쓰면

$$\begin{aligned} L_D(\alpha) &= \alpha_1 + \alpha_2 + \text{const} \\ &\quad - \frac{1}{2}(y_1 y_1 \mathbf{x}_1^T \mathbf{x}_1 \alpha_1^2 + y_2 y_2 \mathbf{x}_2^T \mathbf{x}_2 \alpha_2^2) \\ &\quad + 2y_1 y_2 \mathbf{x}_1^T \mathbf{x}_2 \alpha_1 \alpha_2 + 2 \left( \sum_{i=3}^N \alpha_i y_i \mathbf{x}_i^T \right) (y_1 \mathbf{x}_1 \alpha_1 + y_2 \mathbf{x}_2 \alpha_2) \\ &\quad + \text{const} \end{aligned}$$
(2.16)

식 (2.16)에서

$$\begin{aligned} v_j &= \sum_{i=3}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x}_j \\ &= u_j^{\text{old}} + b^{\text{old}} - \alpha_1^{\text{old}} y_1 \mathbf{x}_1^T \mathbf{x}_j - \alpha_2^{\text{old}} y_2 \mathbf{x}_2^T \mathbf{x}_j \end{aligned}$$

여기서,  $u_j^{\text{old}} = \mathbf{x}_j^T \mathbf{w}^{\text{old}} - b^{\text{old}}$  이며,  $\mathbf{x}_j$  의 결과 값이다.

$K_{11} = \mathbf{x}_1^T \mathbf{x}_1, K_{22} = \mathbf{x}_2^T \mathbf{x}_2, K_{12} = \mathbf{x}_1^T \mathbf{x}_2, v_j = \sum_{i=3}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x}_j, \gamma = \alpha_1 + s\alpha_2, s = y_1 y_2$  라 두

면, 식 (2.16)은 다음과 같이 된다.

$$\begin{aligned}
 L_D(\alpha) &= \alpha_1 + \alpha_2 - \frac{1}{2}(K_{11}\alpha_1^2 + K_{22}\alpha_2^2 + 2sK_{12}\alpha_1\alpha_2 \\
 &\quad + 2y_1v_1\alpha_1 + 2y_2v_2\alpha_2) + \text{const} \\
 &= \frac{1}{2}(2K_{12} - K_{11} - K_{22})\alpha_2^2 \\
 &\quad + (1 - s + sK_{11}\gamma - sK_{12}\gamma + y_2v_1 - y_2v_2)\alpha_2 \\
 &\quad + \text{const}
 \end{aligned} \tag{2.17}$$

$\eta = 2K_{12} - K_{11} - K_{22}$  라 두고,  $\alpha_2$  의 계수는 다음과 같다.

$$\begin{aligned}
 &1 - s + sK_{11}\gamma - sK_{12}\gamma + y_2v_1 - y_2v_2 \\
 &= y_2(E_1^{\text{old}} - E_2^{\text{old}}) - \eta\alpha_2^{\text{old}}
 \end{aligned} \tag{2.18}$$

여기서  $E_i^{\text{old}} = u_i^{\text{old}} - y_i$  로써 예측 오차이다.

식 (2.18)을 식 (2.17)에 대입하여 정리하면 식 (2.19)과 같이 된다.

$$L_D(\alpha) = \frac{1}{2}\eta\alpha_2^2 + (y_2(E_1^{\text{old}} - E_2^{\text{old}}) - \eta\alpha_2^{\text{old}})\alpha_2 + \text{const} \tag{2.19}$$

위 식을  $\alpha_2$  에 대해 1 계 및 2 계 미분을 구하면 다음과 같다.

$$\begin{aligned}
 \frac{dL_D}{d\alpha_2} &= \eta\alpha_2 + (y_2(E_1^{\text{old}} - E_2^{\text{old}}) - \eta\alpha_2^{\text{old}}) \\
 \frac{d^2L_D}{d\alpha_2^2} &= \eta
 \end{aligned} \tag{2.20}$$

여기서 목적함수가 최대값을 가지기 위해서는 1 계 미분의 값이 0 이어야 한다. 따라서,

$$\alpha_2^{\text{new}} = \alpha_2^{\text{old}} + \frac{y_2(E_1^{\text{old}} - E_2^{\text{old}})}{\eta} \tag{2.21}$$

이 된다. 식 (2.15)의 경계값을 고려하면

$$\alpha_2^{\text{new,clipped}} = \begin{cases} H & \text{if } \alpha_2^{\text{new}} \geq H; \\ \alpha_2^{\text{new}} & \text{if } L < \alpha_2^{\text{new}} < H; \\ L & \text{if } \alpha_2^{\text{new}} \leq L; \end{cases} \quad (2.22)$$

그리고,

$$\alpha_1^{\text{new}} = \alpha_1^{\text{old}} + s(\alpha_2^{\text{old}} - \alpha_2^{\text{new}}) \quad (2.23)$$

#### 2.4.2 한계값 $b$ 의 결정

예측오차  $E(\mathbf{x}, y)$ 와 예측오차의 변화량  $\Delta E(\mathbf{x}, y)$ 는 다음과 같다.

$$E(\mathbf{x}, y) = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x} - b - y$$

$$\Delta E(\mathbf{x}, y) = \Delta \alpha_1 y_1 \mathbf{x}_1^T \mathbf{x} + \Delta \alpha_2 y_2 \mathbf{x}_2^T \mathbf{x} - \Delta b$$

한계값  $b$ 는  $E(\mathbf{x}, y)^{\text{new}} = 0$  일 때이므로, 식(2.23)에 의하여 구하여 진다.

$$E(\mathbf{x}, y)^{\text{new}} = E(\mathbf{x}, y)^{\text{old}} + \Delta E(\mathbf{x}, y)$$

따라서,

$$\Delta b = E(\mathbf{x}, y)^{\text{old}} + \Delta \alpha_1 y_1 \mathbf{x}_1^T \mathbf{x} + \Delta \alpha_2 y_2 \mathbf{x}_2^T \mathbf{x} \quad (2.24)$$

가 된다.

## 2.5 Multi-class SVMs 의 전략

기본적으로 SVM 은 이진 분류를 수행하며, 여러 클래스를 가지는 실제 응용분야에의 적용에는 한계가 있다. 그래서 이를 극복하기 위한 방안으로 이진 분류의 조합에 대한 다양한 전략들이 제시되었다. 대표적인 전략으로는 one-against-all<sup>[12]</sup>, one-against-one<sup>[13-14]</sup>, directed acyclic graph<sup>[15]</sup> 및 binary tree<sup>[16]</sup>등과 같은 것들이 있다. 본 연구에서는 많이 사용되고 있는 기법인 one-against-all 방법과 one-against-one 방법을 이용한다.

### 2.5.1 One-against-all 기법<sup>[12]</sup>

이 방법은 초기 multi-class 분류화를 수행하기 위해 사용된 모델이다.  $k$  개의 상태를 분류하기 위해  $k-1$  개의 SVM 이 필요하며, 학습데이터는  $k-1$  개 모두 동일하나 상태의 소속을 나타내는 라벨(label)은 수행되는 SVM 에 따라 달라진다. 가령,  $i$  번째 SVM 은 소속  $i$  와 그 나머지를 구별하는 일을 수행하며 소속  $i$  에 해당되는 학습데이터는 +1 값을 가지며 나머지 즉, 다른 소속에 속하는 학습데이터는 -1 값을 가진다. 그래서 구성된 학습데이터를 이용하여 학습하고 미지의 새로운 데이터에 대하여 순차적으로 SVM 의 수행 후 그 결과값이 +1 값을 도출한 SVM 에서 그 상태를 판별하게 된다.

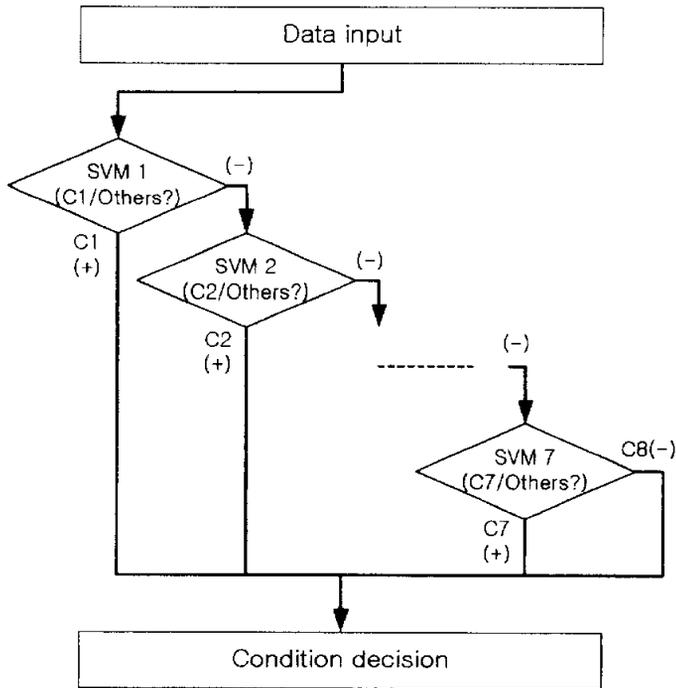
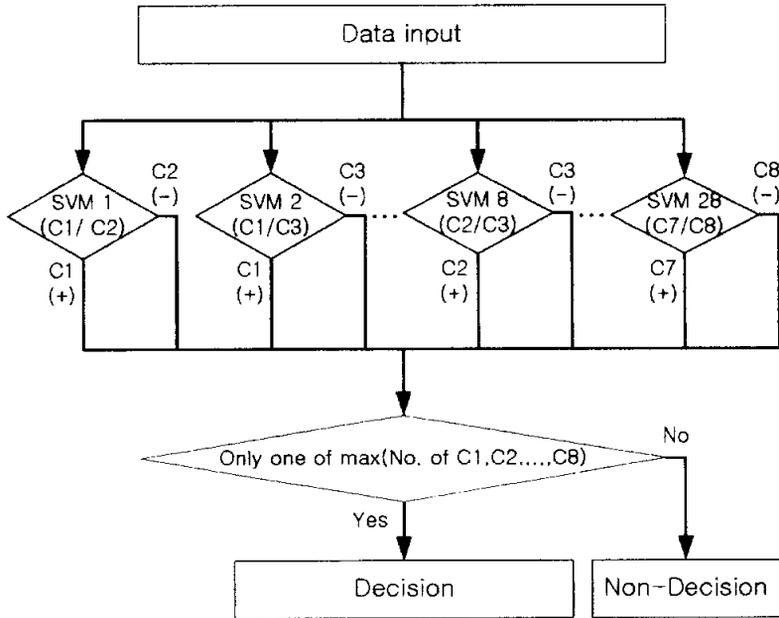


Fig. 2.5 One-against-all approach

### 2.5.2 One-against-one 기법<sup>[13,14]</sup>

이 방법은 one-against-all 방법과는 달리  $k(k-1)/2$  개의 SVM 으로 구성되며, 각각의 학습데이터는 두개의 소속을 나타내는 데이터로만 구성된다. 즉, 첫번째 SVM 은 class 1 과 class 2 만으로 구성된 학습데이터를 가지며, 미지에 데이터에 대해서도 class 1 과 class 2 에 대해서만 분류하게 된다. 그래서 다수인  $k(k-1)/2$  개의 SVM 이 필요하다. 미지의 데이터에 대한 판별은 모든 SVM 을 수행한 후 가장 많은 투표 값을 가진 클래스로 그 소속을 판별하게 된다.



**Fig. 2.6** One-against-one approach

## 3. 회전기계의 결합 진동 특성

### 3.1 개요

일반적으로 회전하는 모든 물체는 제작상의 오차나 재료상의 비균질성 등에 의하여 진동이 발생하게 된다. 또한 설비 전체 혹은 설비를 구성하는 부품이나 요소에 하중, 온도, 압력, 열, 화학반응 등의 스트레스(stress)가 작용하고 허용범위를 벗어나게 되면, 고유의 발생기구에 의해 크랙, 박리, 파편, 마멸, 변질, 변형 등의 손상이 발생하고 성장한다. 동시에, 이들 손상에 의해 진동, 발열, 이상음, 음향방출 등의 2차적 현상이 발생한다. 또한 손상의 발생을 거치지 않고 체결부의 느슨함, 송풍기의 서징, 반응장치의 이상반응, 압연장치의 채터링과 같은 이상현상이 발생하고 이것에 의해 진동이나 이상음, 발열 등이 나타난다. 이 장에서는 진동의 관점에서 회전기계에서 발생하는 고장 유형에 따른 진동특성에 대하여 살펴보겠다.

### 3.2 불평형<sup>[17,18]</sup>

저널이 베어링으로 지지되어 있는 회전축을 가진 회전하는 물체를 회전체라 하고, 회전체의 제작 시나 조립시의 정밀도에 의해 발생한 오차, 운전시의 마모나 부식에 의한 변형으로 인한 회전체의 축 중심과 무게중심이 일치하지 않는 상태를 불평형(unbalance)이라 한다.

불평형 상태로 회전하면 원심력(centrifugal force)이 발생하여, 회전체는 어느 한 단면의 중심이 고정 축에 대해 순수 회전운동을 하지 않고 시간이 지남에

따라 단면의 중심이 궤적(orbit)을 그리며 회전 운동하는 휘돌림 운동(whirling motion)을 하게 되어 베어링부에 변동하는 힘이 가해져 진동이 발생한다.

Fig. 3.1과 같이 얇은 원판의 무게중심  $G$ 가 회전축으로부터  $e$ 만큼 편심이 되어 일정 각속도  $\omega$ 로 회전하고 있을 때, 불평형 원심력  $F_u = Me\omega^2$  으로 표현된다. 여기서  $M$ 은 원판의 질량(kg),  $e$ 는 편심(m),  $\omega$ 는 회전각속도(rad/s)이다.

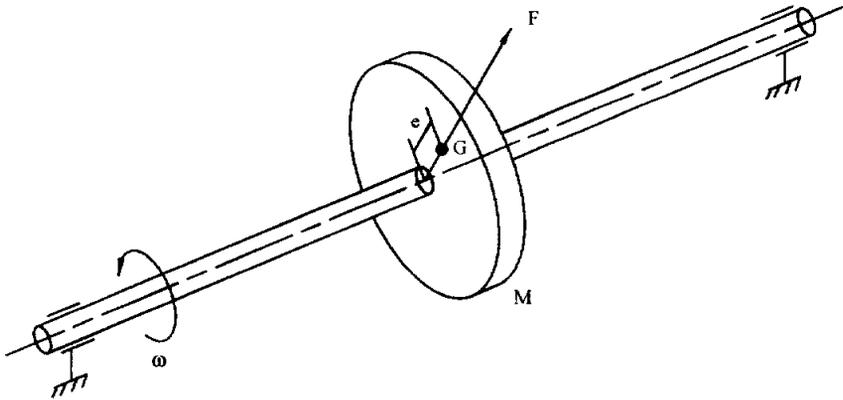


Fig. 3.1 Simple rotor with an unbalance

원심력  $F$ 는 회전축 상에서 일정한 위치에 있기 때문에, 회전축의 회전에 따라서 회전하는 회전 벡터(rotating vector)이다. 이 원심력은 베어링으로 전달 되지만 강(rigid)하여 변형되지 않기 때문에, 베어링은 진동하지 않고 힘만 기초로 전달된다. 그러나, 베어링이 유연하다면 베어링은 진동한다.

원판질량  $M$ 과 편심  $e$ 의 곱인  $U = Me$ 는 불평형(unbalance)이라고 하며, 회전 벡터인 원심력은 1회전에 1회 진동씩으로 힘을 전달하고 그 방향은 축의 직각, 즉 반경방향으로 진동을 발생시킨다. 더욱이, 두 베어링에서 힘의 방향은 같기 때문에, 불평형 진동의 진동수는  $1 \times f_r$  ( $f_r$ 은 회전 주파수)이며 진동

방향은 반경방향이 된다. 또한 두 베어링사이의 위상차는 없다.

Fig. 3.1과 같이 직경에 비해 두께가 작은 원판의 경우는 정적 불평형이 대부분이지만, 직경에 비하여 두께가 큰 경우는 정적 불평형(static unbalance)과 동적 불평형(dynamic unbalance)이 발생할 수 있다. 동적 불평형은 진동수와 진동 방향은 정적 불평형과 같으나, 두 베어링의 위상차는 서로  $180^\circ$ 의 역위상(out of phase)이 된다.

회전체의 불평형을 발생시키는 원인은 제작상의 문제 이외에 회전체의 열팽창차에 의한 불균일 변형, 정지부와 회전체의 접촉(rubbing)에 의한 회전체의 굽힘, 회전체의 마모 및 부식, 이물질의 부착, 회전체의 변형 및 파손 등 원인이 있다. 불평형에 의해 발생하는 진동특성을 다음과 같다.

- 1) 진동신호의 시간 파형은 조화 파형(harmonic waveform)이다.
- 2) 진동신호의 주파수 스펙트럼에서 회전속도의 1X 성분이 크게 나타난다.
- 3) 회전 속도의 증가에 따라 1X성분이 급격히 증가한다.

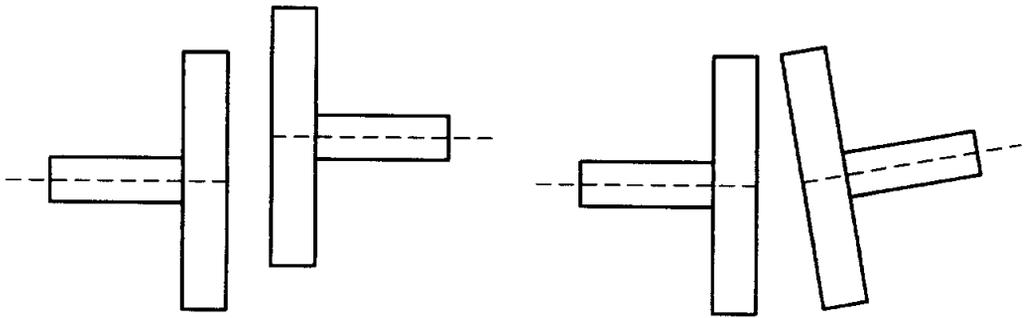
### 3.3 정렬불량<sup>[18]</sup>

정렬불량(misalignment)은 불평형과 같이 진동원인의 대부분을 차지한다. 대부분의 기계는 단품으로 작동되기 보다는 모터 또는 엔진과 같이 동력을 발생시키는 기계요소와 송풍기, 펌프 등과 같이 특별한 용도로 이용되는 기계요소와의 결합으로 이루어져 있다. 때문에 두 기계요소의 결합이 요구되는데 이 때 커플링에 의한 결합이 일반적이다. 정렬불량이라는 것은 구동축과 피동축이 같은 중심선 상에 있지 않기 때문에 높은 진동이 발생하는 현상을 말한다. 정렬불량이 있으면 회전체 축이 강제적으로 굽혀지기 때문에, 외관 상의 초기굽힘이 생기고, 그것에 의해 진동을 발생한다.

정렬불량에는 Fig. 3.2와 같이 편심 정렬불량(parallel misalignment), 편각 정

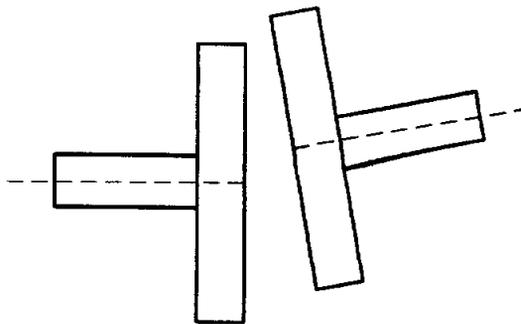
정렬불량(angular misalignment) 그리고 편심 및 편각 정렬불량이 혼합된 복합 정렬 불량의 3가지로 나눌 수 있다. 주요 진동 특성을 살펴보면 아래와 같다.

- 1) 진동 신호의 시간 파형은 조화 파형(harmonic waveform)이다.
- 2) 반경방향의 진동 주파수 스펙트럼에서 1X 성분과 2X 성분을 주요 성분으로 나타나며 대부분의 경우 1X 성분보다 2X성분이 크게 나타난다.
- 3) 축 방향의 진동주파수 스펙트럼에서 1X 성분이 크게 나타난다.
- 4) 전형적인 축의 휘돌림은 전향(forward)이며 궤적(orbit)은 바나나 형상이다.
- 5) 진동은 하중에 민감하고, 진폭은 하중의 증가에 따라 증가한다.



(a) Parallel misalignment

(b) Angular misalignment



(c) Combined misalignment

**Fig. 4.2** Misalignment type

불평형과 정렬불량은 기계 고장 중 가장 일반적인 형태로 매우 빈번하게 나타나며, 모든 고장의 원인이 되기 때문에 항상 중요하게 생각해야 한다. 또한 심하지 않는 정렬불량에 의한 진동은 축 중심이 회전중심과 어긋나기 때문에 불평형에 의한 진동과 같이 회전 속도 성분의 피크가 높게 나타나게 된다. Table 3.1에는 불평형과 정렬불량에 의한 진동특성의 차이를 나타내었다.

**Table 3.1** The difference between unbalance and misalignment

불평형 진동	정렬 불량
<ul style="list-style-type: none"> <li>• 1X에서 높은 진동 발생</li> <li>• 반경방향에 대한 높은 진동 진폭</li> <li>• 온도변화와 무관</li> <li>• 속도증가와 비례한 진동 특성</li> </ul>	<ul style="list-style-type: none"> <li>• 1X에 대한 높은 하모닉 성분</li> <li>• 높은 축방향 진동</li> <li>• 온도변화에 따른 진동특성 변화</li> <li>• 속도변화에 둔감</li> </ul>

### 3.4 공진

공진(resonance) 현상은 외부에서 전달되는 강제진동의 주파수가 구조의 고유진동수와 같거나 유사할 경우 진동이 증폭되는 현상을 말한다. 외부 가진력의 근원은 대체로 회전축의 불평형 진동이거나 유체의 난류(turbulence) 유동에서 발생하는 진동이 대부분이다. 회전축의 작은 불평형 양은 기계와 기계에 조립된 여러 부품에 진동으로 전달되며 그것의 질량과 강성에 의해 결정되는 고유진동수와 비슷해질 경우 공진이라고 불리는 높은 진동이 발생한다.

공진에 의한 진동의 특성을 살펴보면 다음과 같다.

- 1) 원심력에 의한 진동으로 1X 성분만 나타난다.
- 2) 약간의 속도 변화에도 진동 특성이 급격히 감소한다. 이는 공진점만 피하게 되면 공진현상이 사라진다.

- 3) X, Y 방향의 강성차이로 인해 양방향의 공진점이 서로 다르다
- 4) 진동의 크기에 관계없이 공진에 의한 진동은 시간이 지남에 따라 점점 커진다.

이상의 3가지 진동 원인(불평형, 정렬불량, 공진)에 의한 진동은 가장 일반적인 형태의 진동으로 전체 진동문제의 90%이상을 차지하고 있다. 현장에서 발생하는 이들 간의 대략적인 비율은 불평형 진동은 40%, 축 정렬불량은 30%, 공진 20% 정도이다.

### 3.5 베어링 결함

베어링(bearing)은 회전기계의 운전 신뢰성 및 성능에 직접적인 영향을 미치는 가장 중요한 핵심 기계요소 중의 하나이다. 일반적인 회전기계에서 발생하는 많은 문제들은 주로 베어링 자체의 결함이나 또는 베어링과 연관되어 발생한다. 따라서 베어링에서 발생하는 사소한 문제는 회전기계 시스템 전체의 운전에 영향을 미칠 뿐만 아니라 시스템의 운전 정지에 따른 엄청난 경제적 손실을 초래한다. 여기서는 마찰 손실이 적고 수명이 긴 구름요소 베어링의 일반적인 결함특성에 관하여 설명한다.

Fig. 3.4는 대표적인 구름요소 베어링인 볼 베어링의 구조를 나타내고 있으며, 외륜, 내륜, 전동체 그리고 리테이너로 구성되어 있다. 볼 베어링은 구조상 극히 작은 틈새(clearance)를 갖고 있으며, 축에서부터 전달된 진동 신호는 베어링의 전동체를 통하여 베어링의 외륜까지 전달되어져서 결국에는 베어링의 하우징까지 전달 되어진다.

볼 베어링의 고장의 원인에 대한 특정한 주파수가 검출되며, 이 때 측정된 진동의 크기로 베어링의 상태를 알 수 있다. 볼 베어링에서 나타나는 기본적인 4가지 진동 주파수는 다음과 같다.

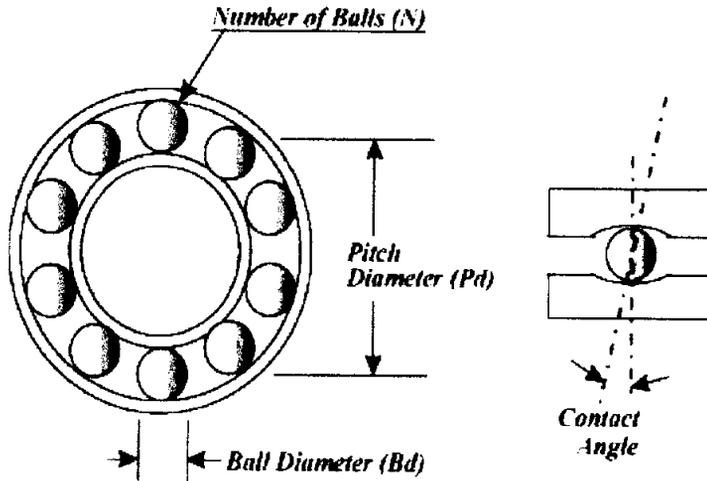


Fig. 3.4 Geometry of ball bearing

- 기본열 주파수(fundamental train frequency, FTF):

$$FTF = \frac{rps}{2} \left[ 1 - \frac{Bd}{Pd} \cos \phi \right]$$

- 볼 자전 주파수(ball spin frequency, BSF):

$$BSF = \frac{Pd}{2Bd} (rps) \left[ 1 - \left( \frac{Bd}{Pd} \right)^2 \cos^2 \phi \right]$$

- 외륜 통과 주파수(ball pass frequency of outer race, BPFO):

$$BPFO = N(FTF)$$

- 내륜 통과 주파수(ball pass frequency of inner race, BPFI):

$$BPFI = N(rps - FTF)$$

여기서,  $Bd$  는 볼의 직경,  $Pd$  는 피치 직경,  $N$  은 볼의 수,  $rps$  는 내륜의 1초당 회전수,  $\phi$  는 접촉각을 말한다.

## 4. 특징 추출

### 4.1 개요

회전기계의 진동 신호는 기계의 각 상태에 따른 일정한 진동 특징을 가지고 있다. 그러므로 진동을 측정하고 분석함으로써 기계의 상태 파악과 각종 결합 원인을 진단할 수 있다. 진동의 측정은 시간에 따른 진동 진폭의 변화를 측정하게 되며 측정된 시간 신호를 기반으로 적절한 신호처리기법을 통하여 기계의 상태에 따른 진동 특징을 추출할 수 있다. 이러한 과정을 특징추출(feature extraction)이라고 하며, 특징 추출의 기본원칙은 다음과 같다.<sup>[19]</sup>

- 1) 특징량을 정확하게 선택하여야 한다.
- 2) 동일한 특징량은 시각에 따라 변하지 않고 일정한 값이어야 한다.
- 3) 서로 다른 상태의 특징량 사이에는 뚜렷한 구별이 있어야 한다.
- 4) 특징량의 수는 각 상태를 충분히 표현할 수 있는 조건 하에서 가능한 적어야 한다.

### 4.2 특징 추출 파라미터<sup>[20]</sup>

#### 4.2.1 시간 영역

##### 1) 평균(Mean)

평균은 시계열 신호의 전체를 대표하는 값으로써 식(4.1)과 같이 표현된다.

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i \quad (4.1)$$

평균은 모든 관측값들에 포함된 정보에 기초하지만 극단적인 관측값의 영향에 민감하다. 즉, 아래와 같은 성질을 가지고 있다.

① 계열 신호의 각각의 값들의 편차의 합은 0이다.

$$\sum_{i=1}^n (x_i - \bar{x}) = 0$$

② 평균에 대한 시계열 신호의 각각의 값들의 편차의 제곱합은 다른 임의의 값에 대한 각각의 값들의 제곱합보다 작다.

$$\sum_{i=1}^n (x_i - \bar{x})^2 \leq \sum_{i=1}^n (x_i - a)^2$$

## 2) 표준편차(Standard deviation)

시계열 신호의 산포를 측정하는 척도로 분산과 표준편차가 사용가능하지만 표준편차가 분산에 비해 의미가 있는 척도이다. 분산은 관측값들의 제곱한 단위를 사용하지만 표준편차는 관측값과 같은 단위를 사용한다. 따라서 표준편차를 이용해서 시계열 신호의 구조를 해석하기가 용이하다. 표준편차의 정의식은 식(4.2)와 같다.

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.2)$$

## 3) 왜도(Skewness)

시계열 신호에 대한 관측값들의 확률밀도함수 분포의 대칭 정도와 방향을 나타내는 값을 왜도라고 한다. 평균과 분산이 차원을 가지고 있지만 왜도는 무

차원수이다. 만일 단봉형 분포에서 긴 왼쪽 꼬리를 가지면 음의 왜도(negative skewness)를 가지며 좌비대칭이라 하고, 오른쪽으로 긴 꼬리를 가지면 양의 왜도를 가지며 우비대칭이라 한다. 왜도는 왜도 계수의 절대치가 커질수록 비대칭정도가 커짐을 의미하고 우비대칭이면 양수, 좌비대칭이면 음수, 대칭이면 0의 값을 가진다. 왜도를 계산하는 방법은 다음과 같다.

① Pearson 방법

평균과 중앙값(또는 최빈값)의 차이를 표준편차로 나눈 값으로 구하는 방법이다.

$$\beta_1 = \frac{\bar{x} - \text{mode}}{\sigma} \approx \frac{3(\bar{x} - \text{median})}{\sigma}$$

여기서, mode는 최빈값, median은 중앙값을 의미한다.

② 평균에 대한 표준편차의 비를 이용한 방법

왜도의 적률계수(moment coefficient of skewness 혹은 anomaly)를 구하는 방법으로 가장 많이 사용된다. 평균으로부터 편차를 세제곱하여 표준편차의 세제곱으로 나눈 값이다.

$$\beta_1 = \frac{\frac{1}{n} \sum_{i=1}^n x_i^3}{\sigma^3} \tag{4.3}$$

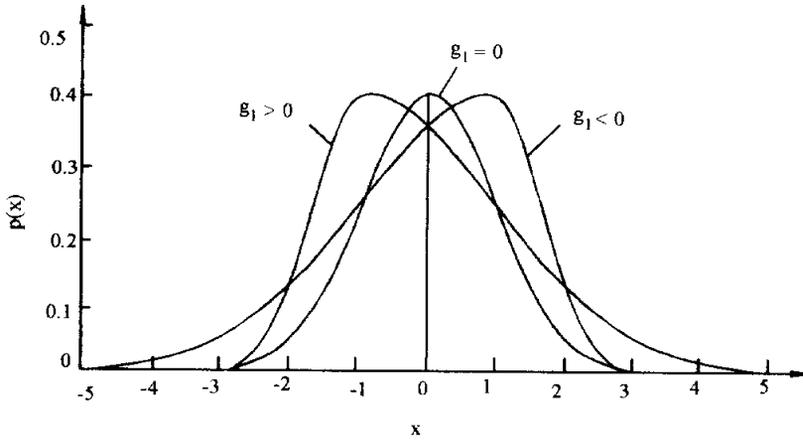


Fig. 4.1 The relation of skewness and probability density function

#### 4) 첨도(Kurtosis)

첨도는 파형의 4차 모멘트를 표준편차  $\sigma^4$  으로 나누어 규격화한 값으로 파형의 진폭 크기와 관계없이 파형의 형태에 의해 결정된다. 또한 피크치가 강조되는 베어링이나 기어등에서 얻어지는 신호의 정량화, 평가 및 진단에 이용된다.

첨도는 시계열 신호의 확률밀도함수 분포가 갖는 첨예의 정도를 나타내는 측도이다. 앞에서 설명한 평균, 표준편차, 왜도가 모두 같다고 하더라도 자료의 분포 형태가 다른 경우가 있을 수 있으며, 따라서 자료의 양적 구조를 나타내기 위해 관측값들이 중심에 집중되는 정도를 나타내는 값인 첨도가 필요하게 된다. 첨도의 적률계수의 정의는 식(4.4)와 같다.

$$\beta_2 = \frac{\frac{1}{n} \sum_{i=1}^n x_i^4}{\sigma^4} \quad (4.4)$$

시계열 신호가 정규분포를 가질 경우 첨도 계수는 3이며, 첨도 계수가 3 이

상일 경우 정규분포보다 뾰족한 분포가 되고(급첨: leptokurtic), 3보다 작을 경우 완첨(platykurtic)이 된다.

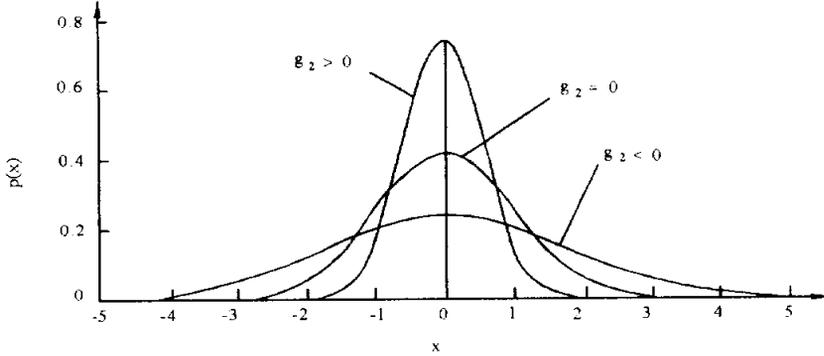


Fig. 4.2 The relation of kurtosis and probability density function

### 5) 실효치(RMS)

진동의 심한 정도를 나타내는 특성인 진동 진폭을 정량화 하는 하나의 방법으로써 RMS값을 사용하고 있다. 이는 평균치의 정보나 scatter의 정보(분산)가 포함되어 있으며 시간에 대한 변화량을 고려하고 진동의 파괴적 능력을 나타내는 에너지량과 직접 관련된 진폭을 표시하므로 진동 크기의 표현에 가장 적절하다. RMS의 정의는 식(4.5)와 같다.

$$x_{rms} = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}} \quad (4.5)$$

### 6) 형상계수(Shape factor)

진동의 overall값에 대한 진동 평균의 비를 나타낸다.

$$S/F = \frac{x_{rms}}{\bar{x}} \quad (4.6)$$

## 7) 파고율(Crest factor)

진동의 Peak값과 overall값의 비를 나타내며, 베어링이나 기어의 결함을 식별 하는데 사용되고 있다. 이 값은 신호 검출 센서나 사용되는 증폭기의 gain과 관계없이 파형이 갖는 특징을 나타낸다. 파고율의 정의는 식(4.7)과 같다.

$$C/F = \frac{x_p}{x_{rms}} \quad (4.7)$$

### 4.2.2 주파수 영역

#### 1) Frequency center

Frequency center는 이산 시계열 신호를 전 주파수 대역에서 보았을 때 스펙트럼 밀도의 중심을 나타낸다. 이의 정의식은 식(4.8)과 같이 나타낸다.

연속 신호에 대한 Frequency center는 다음과 같다.

$$F/C = \frac{\int_0^{+\infty} f \cdot s(f) df}{\int_0^{+\infty} s(f) df}$$

이산 신호에 대한 Frequency center의 정의식은 다음과 같다.

$$F/C = \frac{\sum_{i=2}^n \dot{x}_i \cdot x_i}{2\pi \sum_{i=1}^n x_i^2} \quad (4.8)$$

여기서  $s(f)$ 는 파워 스펙트럼을 말한다.

## 2) Mean square frequency

연속 신호에 대한 Mean square frequency는 다음과 같다.

$$\text{MSF} = \frac{\int_0^{+\infty} f^2 \cdot s(f) df}{\int_0^{+\infty} s(f) df}$$

이산 신호에 대한 Mean square frequency는 다음과 같다.

$$\text{MSF} = \frac{\sum_{i=2}^n x_i^2}{4\pi^2 \sum_{i=1}^n x_i^2} \quad (4.9)$$

## 3) Root mean square frequency

$$\text{RMSF} = \sqrt{\text{MSF}} \quad (4.10)$$

## 4) Variance frequency

전 스펙트럼에서 중심 주파수를 중심으로 다른 성분의 주파수들 사이의 분산을 나타내는 값이다.

$$\text{VF} = \frac{\int_0^{+\infty} (f - \text{FC})^2 \cdot s(f) df}{\int_0^{+\infty} s(f) df}$$

또는

$$\text{VF} = \text{MSF} - (\text{FC})^2 \quad (4.11)$$

## 5) Root variance frequency

$$\text{RVF} = \sqrt{\text{VF}} \quad (4.12)$$

### 4.2.3 Entropy 영역

#### 1) Entropy estimation 및 entropy error

엔트로피(Entropy)라는 용어는 정보이론에만 등장하는 것이 아니고 물리학이나 화학 등에서 에너지의 상태를 표시하기 위하여 오래 전부터 사용되어 왔다. 그러나 정보이론의 체계에서 정의되는 엔트로피의 개념은 이러한 자연과학적 의미에서 벗어나 정보의 양(amount of information)을 평가하는 기준으로서 정보공학적 의미를 갖는다.<sup>[22]</sup> 즉, 엔트로피는 불확실성의 척도로서 사용되어진다. 이 개념은 1940년대에 Shannon에 의해 제시되었었다.

확률론적인 관점에서 측정치와 실제 파라미터 벡터  $\mathbf{x}$  사이의 오차  $v_i$ 는 확률변수(random variables)이며  $Z^m$ 에 속한다. Entropy function은 식 (4.13)과 같이 정의된다.

$$H(x) = \int p(x) \cdot \ln p(x) dx \quad (4.13)$$

여기서,  $\tilde{x}$ 는 estimation error,  $p(\tilde{x})$ 는 밀도함수(density function),  $p(\tilde{x}/z^m)$ 는 조건밀도함수(conditional density function), 그것의 moments  $E\{x^n\}$ ,  $Z^m$ 은 상태 공간내의 측정치의 집합을 나타낸다. 또한 아래의 Orthogonal- projection이론에 의하여 entropy error값을 계산할 수 있다.<sup>[21]</sup>

#### [Orthogonal-Projection 이론]

- ①  $\hat{x}(k/m) \in Z^m$
- ②  $\tilde{x}(k/m) = \hat{x}(k/m) - x(k)$ 은  $Z^m$ 내에서 모든 벡터들은 직교이다.
- ③  $\hat{x}(k/m)$ 은 Hilbert 상태공간  $X$ 에서 유일하다.
- ④ estimation error  $\hat{x}(k/m)$ 는  $E\{\|\tilde{x}(k/m)\|^2\}$ 이다. 그리고 error는 최소 공분산을 가진다. 즉  $E\{\tilde{x}(k/m)\tilde{x}^T(k/m)\} = \min$ 을 가진다.

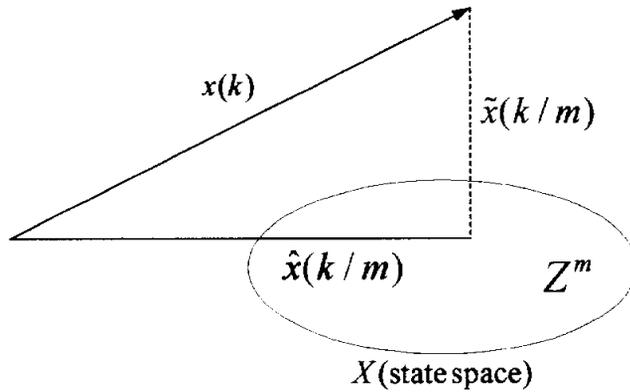


Fig.4.3 Orthogonal projection

## 2) Lower bound와 upper bound

Lower bound와 upper bound는 시계열 신호에 대한 히스토그램과 관련하여 상한과 하한의 경계값을 나타내고 있다. 이들의 정의식은 식 (4.14)와 같다.

$$\begin{aligned} \text{Lower} &= \max(\mathbf{x}) - \frac{\text{delta}}{2} \\ \text{Upper} &= \max(\mathbf{x}) + \frac{\text{delta}}{2} \end{aligned} \quad (4.14)$$

여기서,  $\text{delta} = \frac{\max(\mathbf{x}) - \min(\mathbf{x})}{n-1}$  이다.

## 4.3 웨이블릿 변환 <sup>[23,24]</sup>

웨이블릿 해석은 1980년대에 들어와서 활발하게 연구되기 시작한 이론으로 기존의 푸리에 해석(Fourier analysis)이 가지고 있는 이론적 한계를 극복하기 위하여 시작되었다. 푸리에 해석의 한계는 신호를 분석할 때 그 신호의 시간

정보와 주파수정보를 동시에 파악할 수 없다는 것이다. 이러한 한계를 극복하기 위한 기존의 접근 방법으로는 푸리에 해석에 시간축 상의 윈도우 개념을 접목시킨 Gabor 변환 또는 Short-time 푸리에 해석 등이 있다. 그러나, 이러한 방법들은 근본적인 해결책이 되지 못한다. 그 이유로는 윈도우의 크기에 따라서 분석 가능한 신호의 주파수 영역대가 미리 정해진다는 것과, 각각의 블록들 사이에 신호의 불연속성으로 야기되는 블록현상(Gibbs 현상) 등이 존재하기 때문이다.

한편, 이러한 문제 외에도 푸리에 해석을 통해서 는 전체 신호의 에너지가 특정한 변환 계수에 집중되도록 하기가 힘들다는 단점이 있다. 이러한 단점을 해결하기 위하여 제시된 것이 Karhunen-Loeve 변환이지만, 이 방법은 입력 신호들의 통계적 특성에 따라 각각 다른 Basis들을 찾아야 하기 때문에 실질적 응용이 어렵다는 문제가 있다.

웨이블릿 해석은 그 기원을 입자물리학의 양자장론 중에서 재정규군 (renormalization group)이론, 수학의 조화해석(harmonic analysis) 중에서 Calderon-Zygmund Operator이론, 그리고 신호처리 분야의 다해상도 필터 뱅크 이론 등에 두고 있다.

웨이블릿 해석은 다 해상도(multi-resolution) 특성과 시간-주파수 동시 해석 특성, 그리고 compact support 특성 등으로 인해 국부적으로 존재하는 비정상신호(non-stationary signal)를 분석하는데 우수한 신호처리 기법이다. 웨이블릿 해석은 기저함수를 도입하여 기저 함수의 넓이를 조절함으로써 고주파수 대역과 저주파수 대역의 해상도(resolution)를 높이고, 또 기저 함수의 시간 축에 따라 이동함으로써 각 주파수 성분이 시간에 따른 변화를 표현할 수 있다. 현재 기저 함수는 많은 종류의 함수가 제안되어있고, Fig. 4.4에 실제에서 많이 사용되는 Daubechies 함수를 나타내었다.

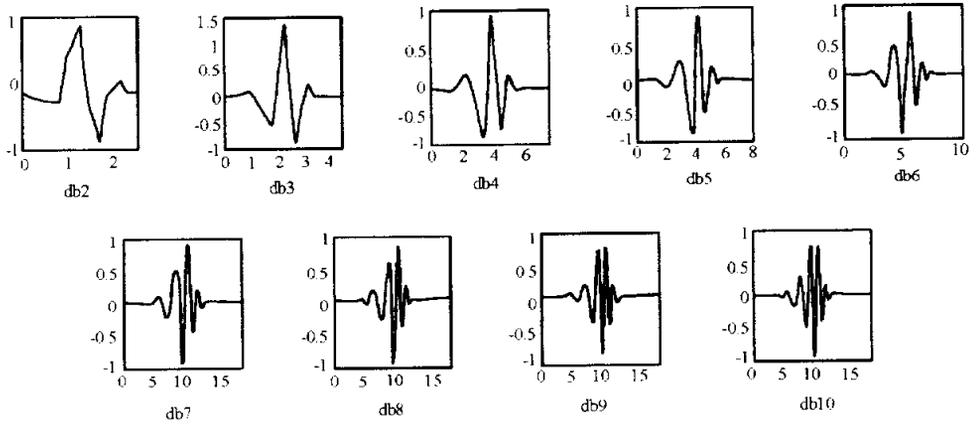


Fig. 4.4 Daubechies basis functions

### 4.3.1 연속 웨이블릿 변환

연속 웨이블릿 변환(Continuous Wavelet Transform, CWT)은 분석 대상 신호  $f(t)$  와 천이된 기저 웨이블릿  $\Psi_{a,b}$  의 곱을 전 시간구간에 대해 적분한 것이다. 시간 함수  $f(t)$  의 연속 웨이블릿 변환은 식(4.15)와 같이 정의된다.

$$CWT(a,b) = \int_{-\infty}^{\infty} f(t)\Psi_{a,b}dt \quad (4.15)$$

$$\Psi_{a,b} = \frac{1}{\sqrt{a}}\Psi\left(\frac{t-b}{a}\right)$$

여기서,  $a$ 는 스케일 파라미터,  $b$ 는 천이 파라미터,  $\Psi$ 는 기저 웨이블릿을 나타낸다. 웨이블릿 변환 결과는 특정한 천이에서의 신호  $f(t)$ 가 스케일되고 천이된 기저 웨이블릿과의 상관성을 의미한다. 웨이블릿 변환에 있어 중요한 개념인 천이는 앞섬과 지연을, 스케일은 확장과 압축을 의미한다.

### 4.3.2 이산 웨이블릿 변환

연속 웨이블릿 변환에서는 모든 스케일에서 웨이블릿 계수를 계산하므로 많은 시간을 요하고 많은 데이터를 생성한다. 이러한 결점을 보완하기 위해서 이산 웨이블릿 변환은 2의 누승이 되는 스케일에서 웨이블릿 변환을 수행함으로써 정확성을 유지한 상태에서 계산시간을 훨씬 줄이는 보다 효율적인 변환을 수행한다. 이산 웨이블릿 변환(Discrete Wavelet Transform, DWT)에 있어 스케일 함수  $\phi(t)$ 와 웨이블릿 함수  $\Psi(t)$ 는 식 (4.16)과 같이 정의된다.

$$\begin{aligned}\phi(t) &= \sum_k c_k \phi(2t - k) \\ \Psi(t) &= \sum_k (-1)^k c_k \phi(2t + k - N + 1)\end{aligned}\tag{4.16}$$

여기서,  $N$ 은 2의 누승인 데이터 개수,  $c_k$ 는 웨이블릿 계수이며, 다음의 조건을 만족해야 한다.

$$\sum_{k=0}^{N-1} c_k = 2, \quad \sum_{k=0}^{N-1} c_k c_{k+2b} = 2\delta\tag{4.17}$$

여기서,  $\delta$ 는 Kronecker 델타를 의미한다.

## 5. 적용 예

### 5.1 냉장고용 소형 왕복동 압축기의 상태 분류<sup>[25]</sup>

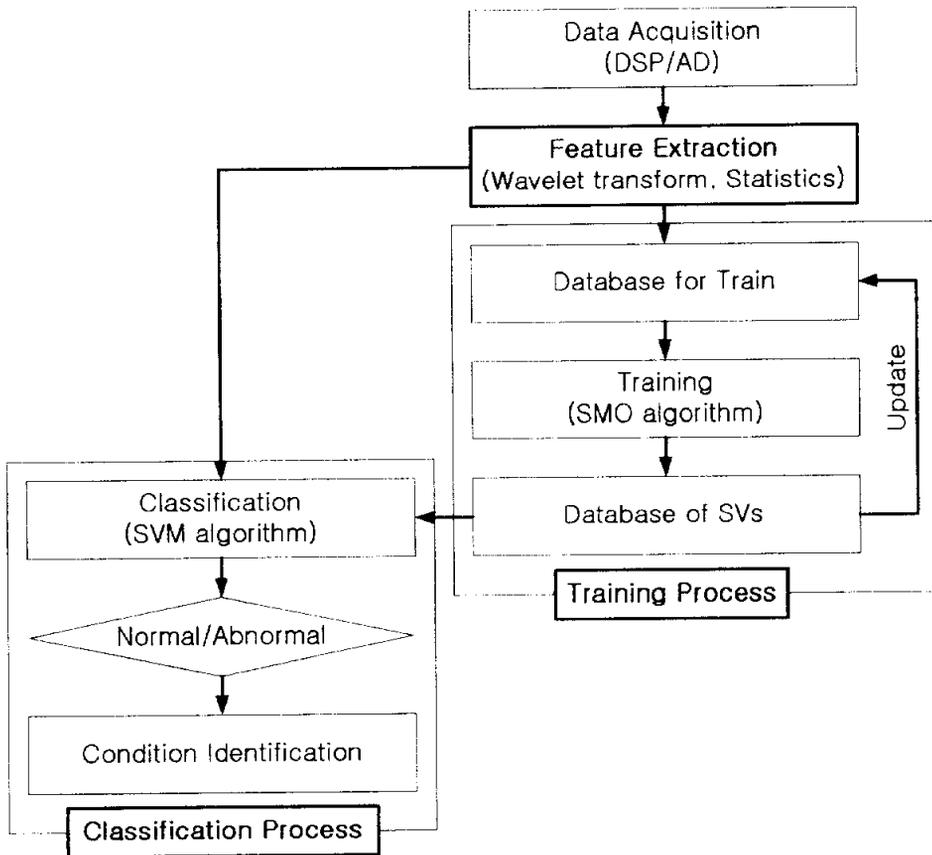
본 연구에서 제시된 알고리즘의 유용성을 평가하기 위하여 실제 생산되는 냉장고용 소형 왕복동 압축기의 상태 분류(정상/이상)에 적용하였다.

#### 5.1.1 상태 분류 시스템

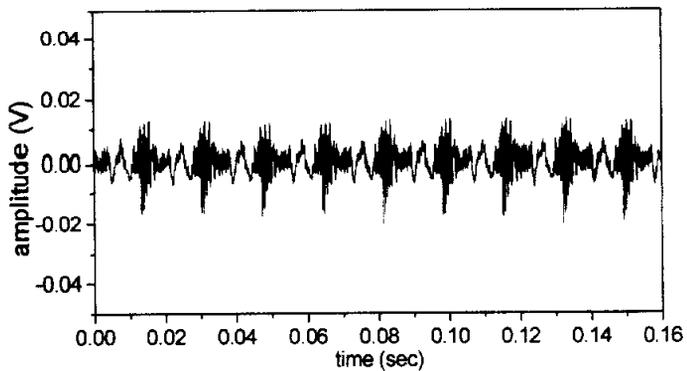
상태 분류 시스템의 전체 구조는 Fig. 5.1과 같다. 분류 대상 기계로부터 가속도계(accelerometer)와 마이크로폰(microphone) 등의 센서를 이용하여 원 신호(raw signal)의 취득, 연속 시계열 데이터의 A/D 변환을 통한 이산 데이터로 변환, 웨이블릿 분석과 통계적 처리 등을 이용하여 특징 추출, SVM을 이용한 훈련 및 분류의 과정으로 구성되어 있다.

#### 5.1.2 데이터 취득

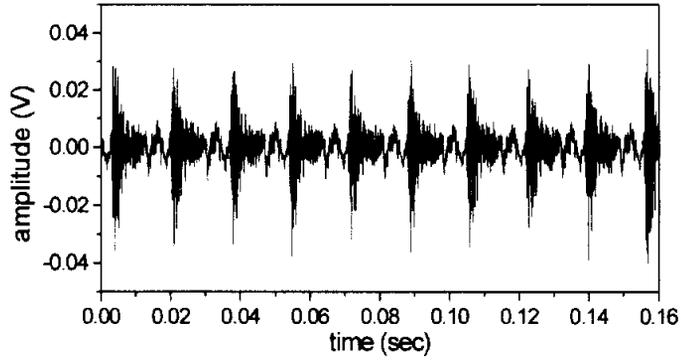
정상 6대, 불량 4대의 반제품 왕복동 압축기를 대상으로 진동 신호를 측정하기 위한 가속도계와 소음 신호를 측정하기 위한 마이크로폰을 이용하여 진동신호와 소음 신호를 연속적으로 취득하였다. 신호 처리를 위한 최대 주파수 범위는 10 kHz이며 샘플링 데이터 개수는 4096개이다. Fig. 5.2는 상태에 따른 소음 신호를, Fig. 5.3에는 진동 신호의 시간 파형을 나타내었다.



**Fig. 5.1** The structure of condition classification

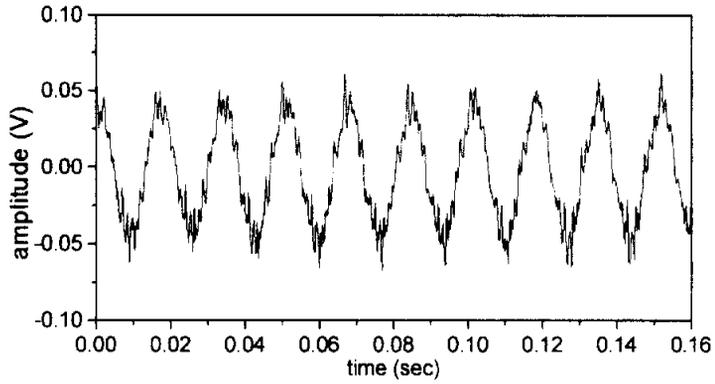


(a) Healthy condition

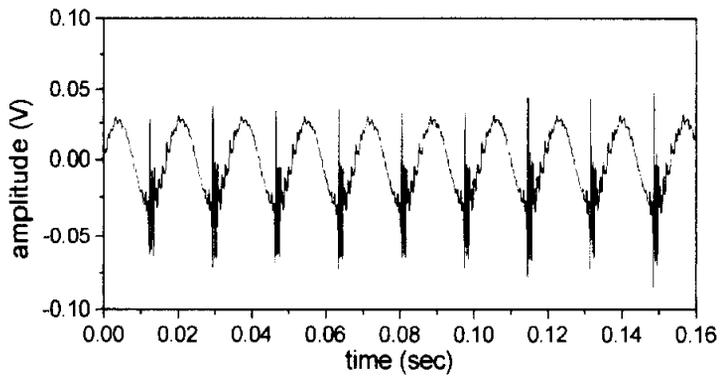


(b) Faulty condition

**Fig. 5.2** Time-waveform noise signals.



(a) Healthy condition



(b) Faulty condition

**Fig. 5.3.** Time-waveform vibration signals

### 5.1.3 특징 추출

대상 기계의 각 상태를 평가하기 위해 각 압축기 당 10 개씩의 시계열 신호를 Daubeches D10 웨이블릿 변환을 수행하였다. 그 결과 저주파수 영역 보다 고주파수 영역에서 정상 및 불량 상태의 구분이 용이함을 알 수 있었고, 따라서 level 1부터 level 4까지의 주파수 영역에 대한 통계적 특징량인 평균, 표준편차, 첨도, 왜도를 각 level 별로 총 16개의 특징량을 구하였다.

Fig. 5.4는 소음 신호에 대한 level 4까지의 웨이블릿 변환 결과를 나타내었으며, Fig. 5.5 는 진동 신호에 대한 결과를 나타내었다.

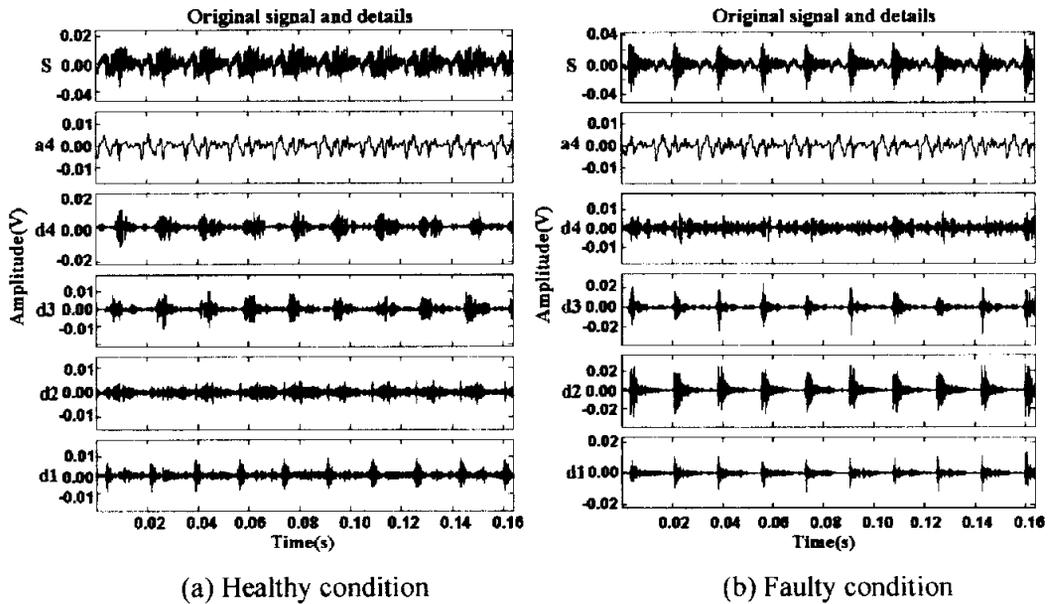


Fig. 5.4. Original and detail sub-bands noise signals

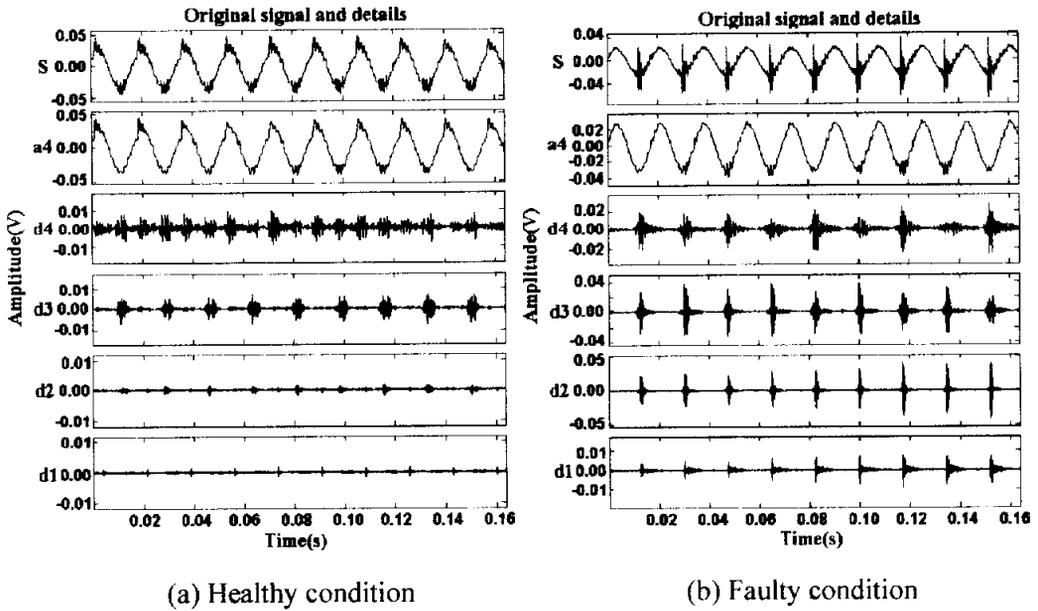


Fig. 5.5. Original and detail sub-bands vibration signals

Fig. 5.6은 소음 신호의 원 신호에 대한 통계적 특징 값을, Fig. 5.7에는 웨이블릿 level 4까지의 특징 값을 나타낸 것이다.

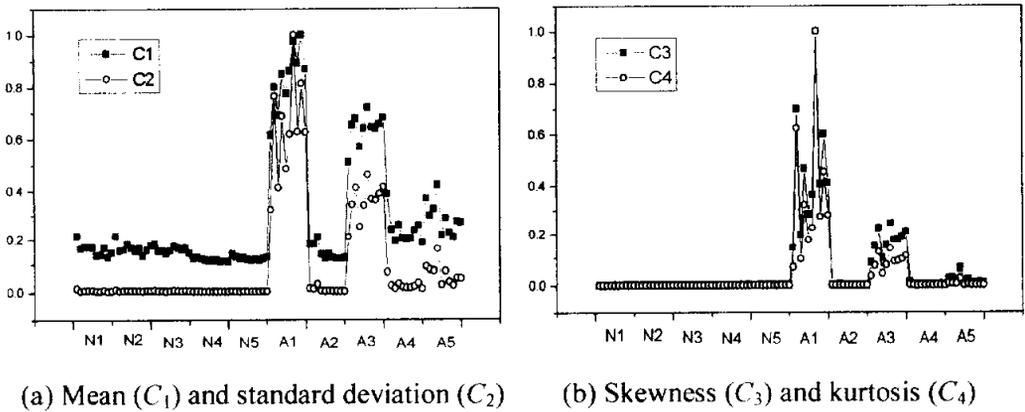


Fig. 5.6. Moment coefficient of the time-waveform noise signal

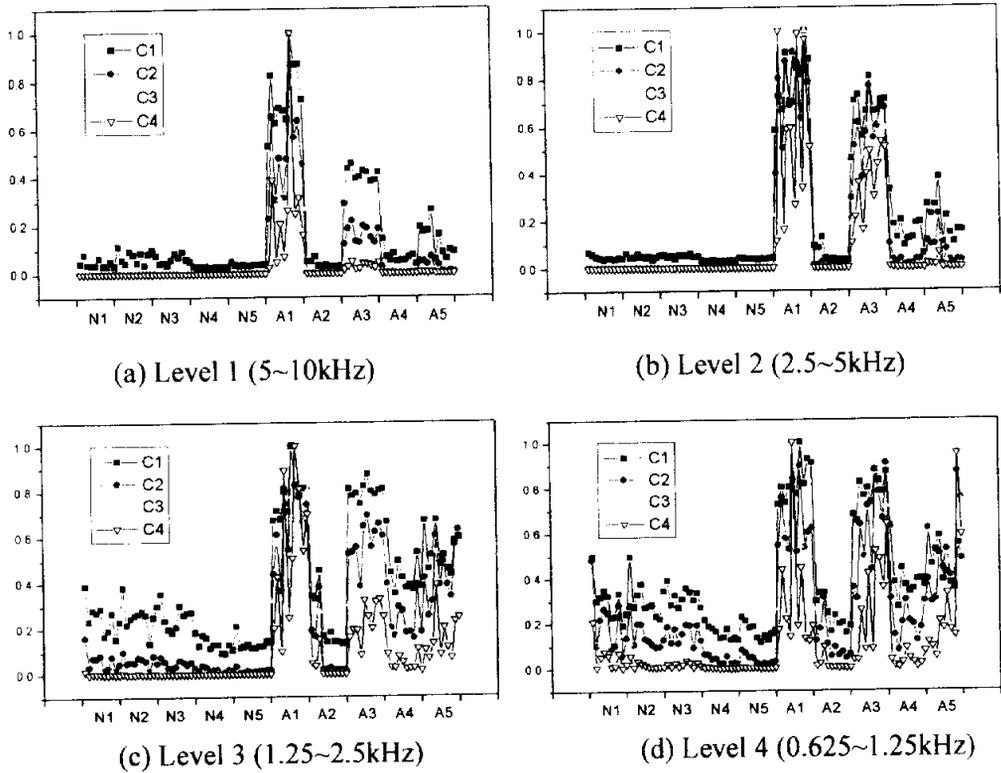


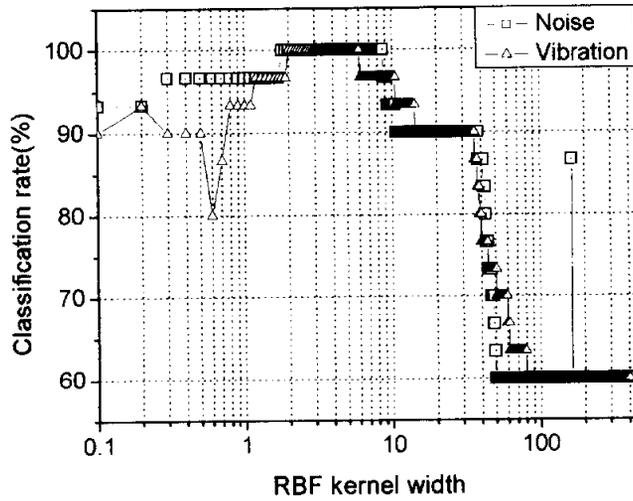
Fig. 5.7. Moment coefficient of wavelet transformed data (Noise)

#### 5.1.4 시뮬레이션 결과

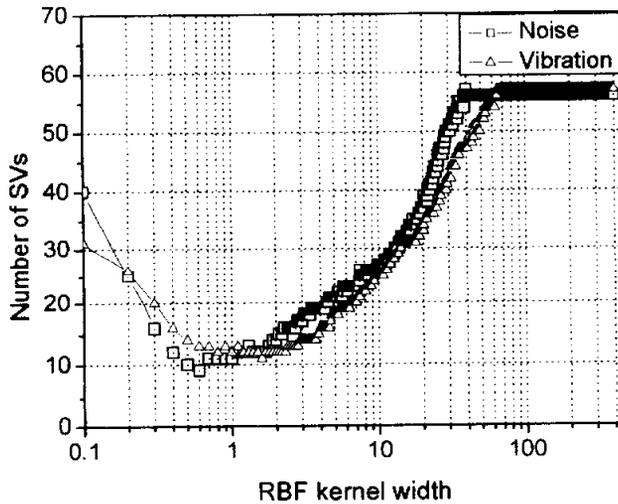
소음 신호와 진동 신호의 원 신호의 시간 신호와 level 4까지의 웨이블릿 변환한 신호를 사용하여 각각에 대하여 시뮬레이션 하였다. 훈련 데이터는 70개 (압축기 1대당 7개씩, 정상 42개, 불량 28개), 테스트 데이터는 30개(압축기 1대당 3개씩, 정상 18개, 불량 12개)를 사용하였다.

SVM의 학습을 위하여 Platt가 제안한 SMO 알고리즘을 사용하였고 커널 함수로는 일반적으로 많이 사용하는 Gaussian RBF 커널을 사용하였다. RBF 커널을 사용함에 있어서 결정해야 할 파라미터인 커널 폭 값은 반복 수행을 통하여 결정한 값(constant width)과 Jack과 Nandi<sup>[24]</sup>에 의해 제안된 표준편차의 평균

을 사용한 값(averaged width)을 사용하였다. Fig. 6.8과 6.9에 RBF 커널 폭에 따른 분류률과 SV의 수를 나타내었다.

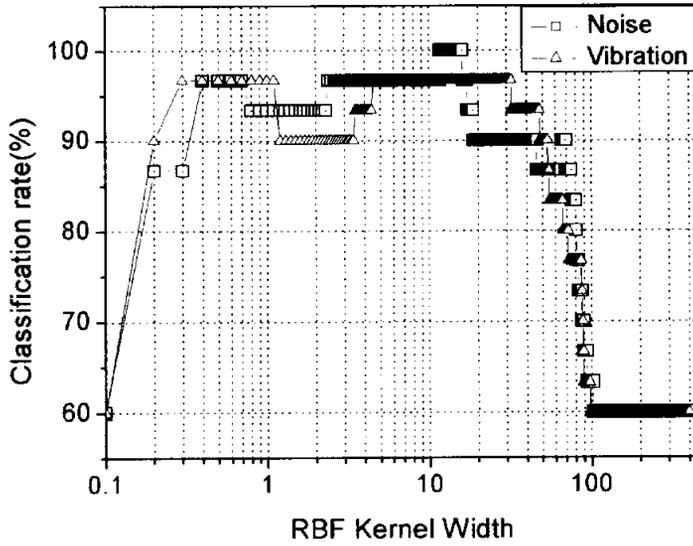


(a) Classification rate

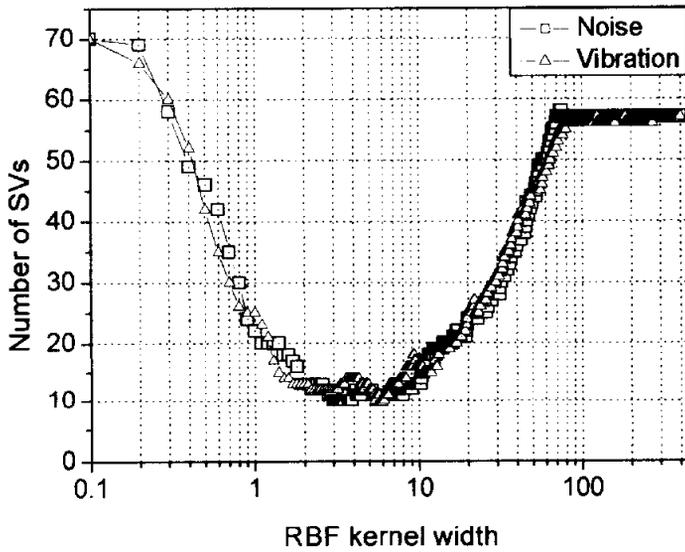


(b) Number of support vectors

Fig. 5.8. RBF kernel width for time-waveform data



(a) Classification rate



(b) Number of support vectors

Fig. 5.9. RBF kernel width for wavelet-transformed data

Table 5.1과 5.2에는 분류 결과를 나타내었다. 소음 신호의 경우, 분류율이 100%이었으며, 진동 신호일 경우 100%, 96.7%였다. 또한 대체로 average width 값을 사용한 것보다 constant width 값을 사용한 경우가 더 나은 분류율을 나타내었다.

**Table 5.1** Performance comparisons of SVMs for time-waveform data

Classifier	Data	Classification rate (%)	RBF kernel width	Number of SVs
SVM (average width)	Noise	93.3 (28/30)	0.198	25
	Vibration	90.0 (27/30)	0.218	25
SVM (constant width)	Noise	100 (30/30)	1.80	13 (optimum)
	Vibration	100 (30/30)	2.00	12 (optimum)

**Table 5.2** Performance comparisons of SVMs for wavelet transformed data

Classifier	Data	Classification rate (%)	RBF kernel width	Number of SVs
SVM (average width)	Noise	86.7 (26/30)	0.278	59
	Vibration	96.7 (29/30)	0.375	53
SVM (constant width)	Noise	100 (30/30)	11.7	18 (optimum)
	Vibration	96.7 (29/30)	5.4	10 (optimum)

## 5.2 회전기계의 결함 진단<sup>[26]</sup>

본 연구에서는 여러 클래스를 가지는 회전 기계의 결함 진단을 위하여 제시된 알고리즘과 전략을 이용하여 유용성을 평가하여 보았으며 동일한 조건 하에서 인공 신경망인 SOFM, LVQ, RBF 신경망과의 분류 결과를 비교, 검토하였다.

### 5.2.1 결함 진단 시스템

상태 분류 시스템의 전체 구조는 Fig. 5.10 과 같다. 대상 기계로부터 가속도계(accelerometer)를 이용하여 원 신호(raw signal)의 취득, 연속 시계열 데이터의 A/D 변환을 통한 이산 데이터로 변환, 웨이블릿 분석과 통계적 처리 등을 이용하여 특징 추출, SVM 을 이용한 훈련 및 분류의 과정, multi-class SVM 을 위한 전략으로 구성되어 있다.

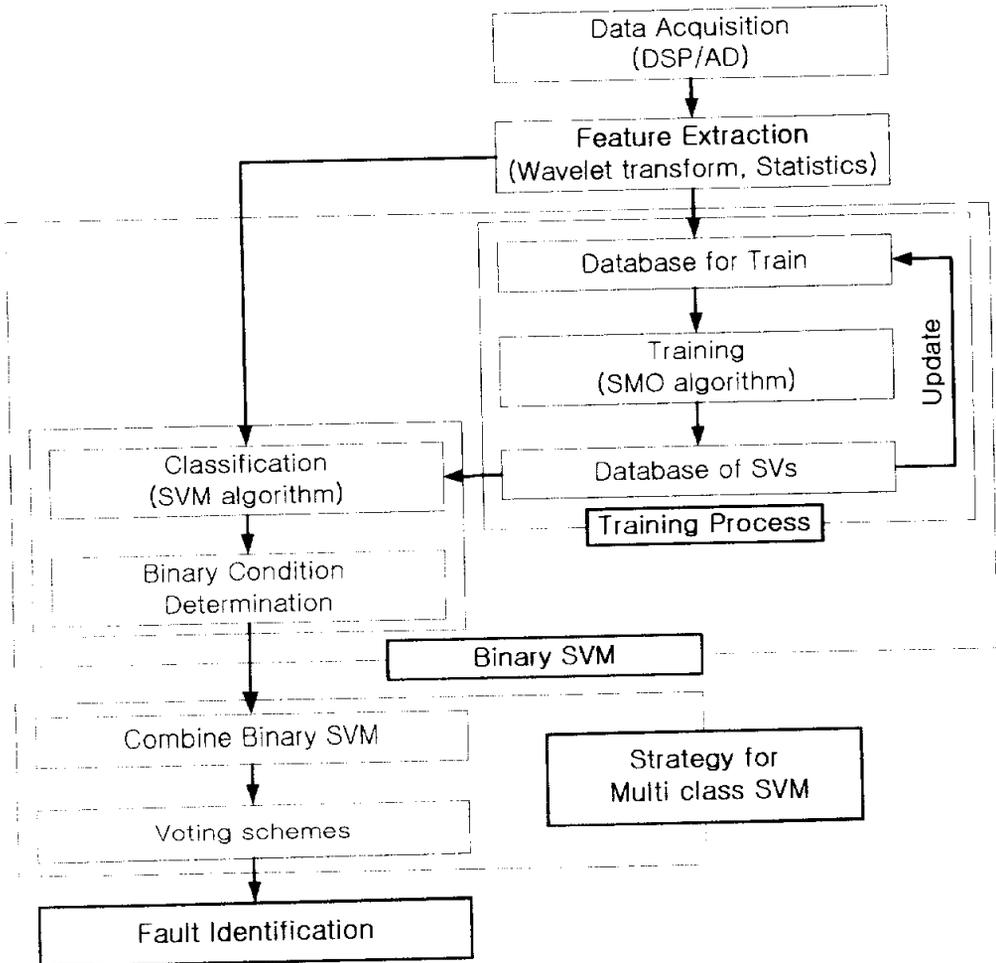


Fig. 5.10. The structure of fault diagnosis system

### 5.2.2. 실험 장치 및 데이터 취득

Fig. 5.11 은 인위적으로 시스템에 결함을 인가할 수 있는 장치로서 3 상 유도 전동기로 구동되며 커플링, 베어링, 디스크 및 축으로 구성되어 있다. 결함은 커플링 부분의 편심(parallel) 및 편각(angular) 정렬불량, 베어링 결함(내륜, 외륜, 볼 및 복합 결함), 디스크의 불평형, 정상상태의 총 8 가지의 상태에 대하여 각각 연속적으로 20 개씩 총 160 개의 시간신호(time signal)를 취득하였다. 그리고 최대 주파수 범위는 5 kHz 이며 샘플링 데이터 개수는 16384 개 이다.

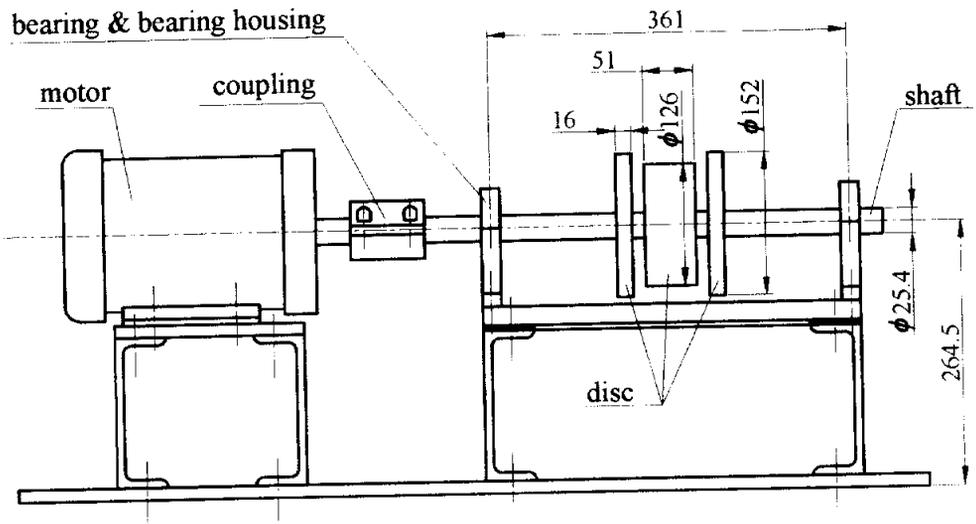
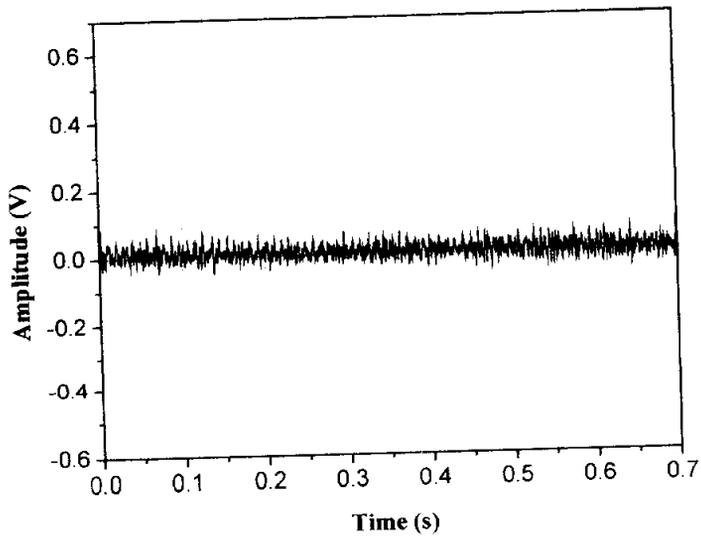


Fig. 5.11. The structure of machinery fault simulator

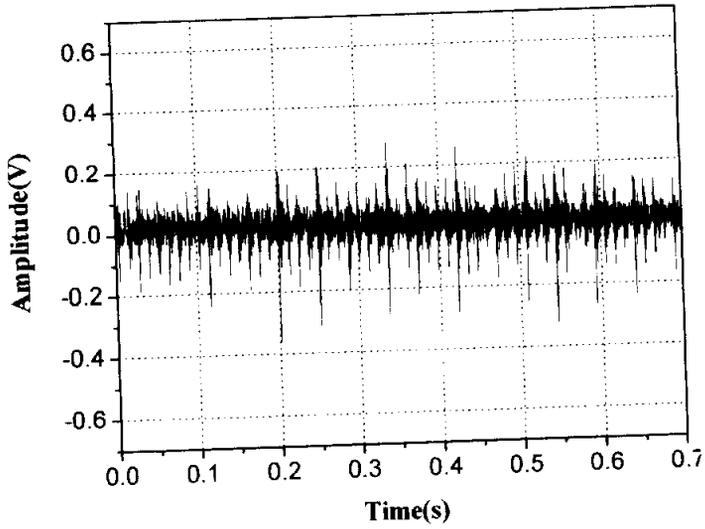
Table 5.3은 실험장치에 인위적으로 부여한 결함에 대해 나타내었다. 그리고 Fig. 5.12에 각 결함의 상태에서 취득한 시간 파형을 나타내고 있다.

**Table 6.3** Description of each fault condition

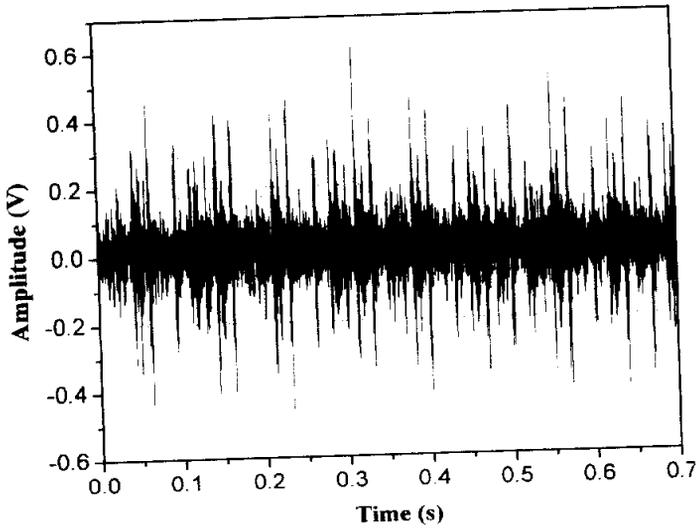
Fault type		Label	Description
Normal		C1	No fault
Bearing	Outer race	C2	A spalling on the outer raceway surface
	Inner race	C3	A spalling on the inner raceway surface
	Ball	C4	A spalling on the ball surface
	Complex	C5	Multiple defects with a outer, inner and ball
Misalignment	Angular	C6	Angular eccentricity : $0.7^\circ$
	Parallel	C7	Parallel eccentricity : 2mm
Unbalance		C8	Mechanical unbalance : 578 g-mm



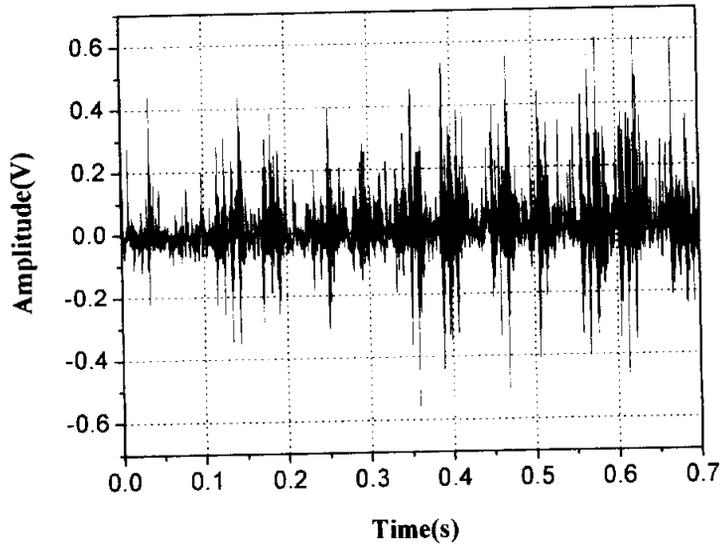
(a) Normal condition



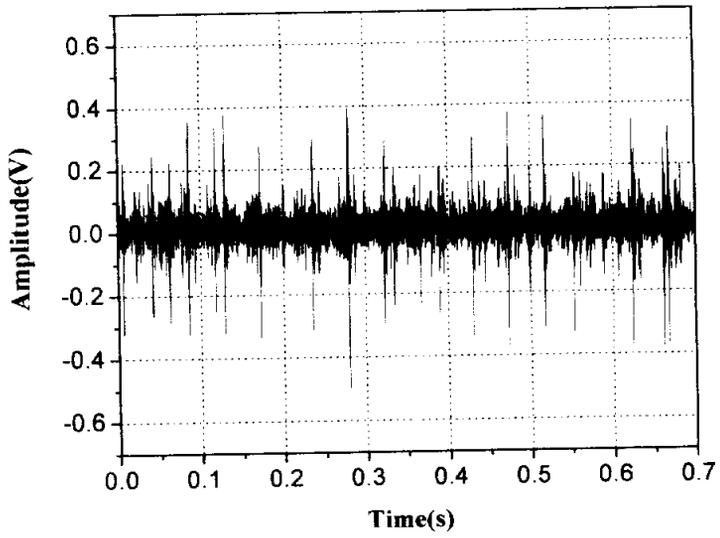
(b) Bearing outer race fault



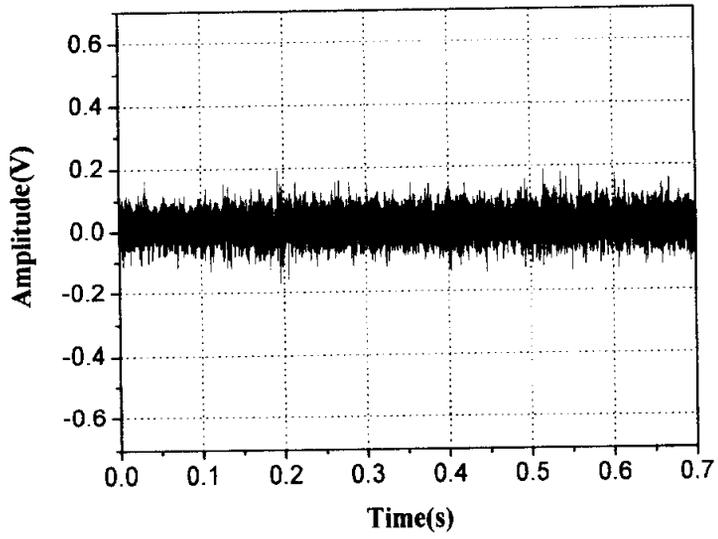
(c) Bearing inner race fault



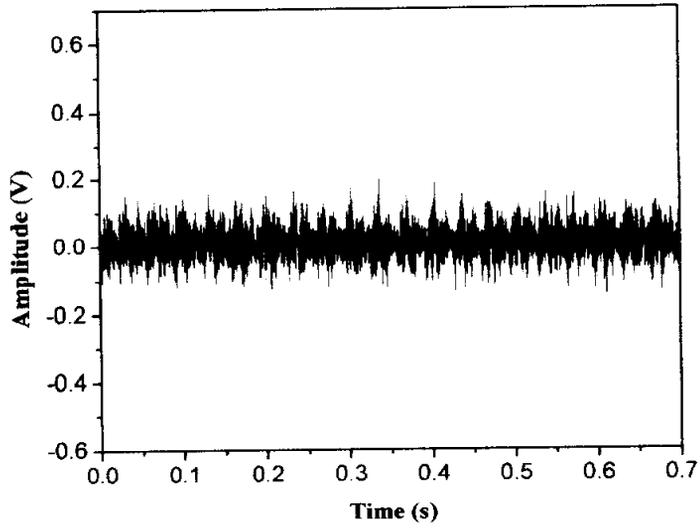
(d) Bearing ball fault



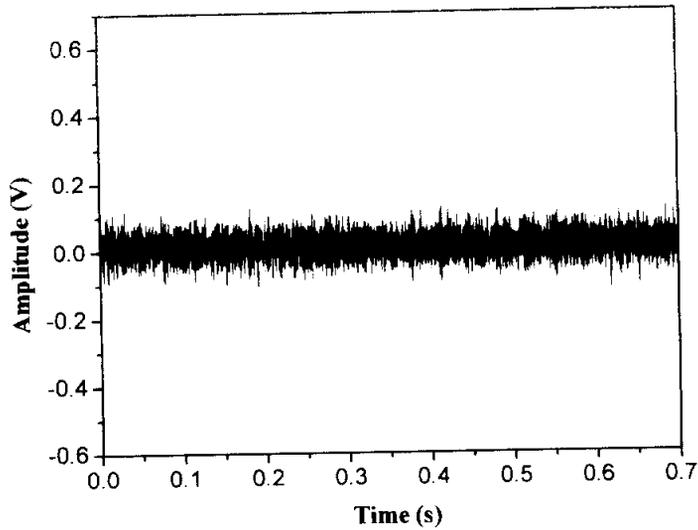
(e) Bearing complex fault



(f) Angular misalignment



(g) Parallel misalignment



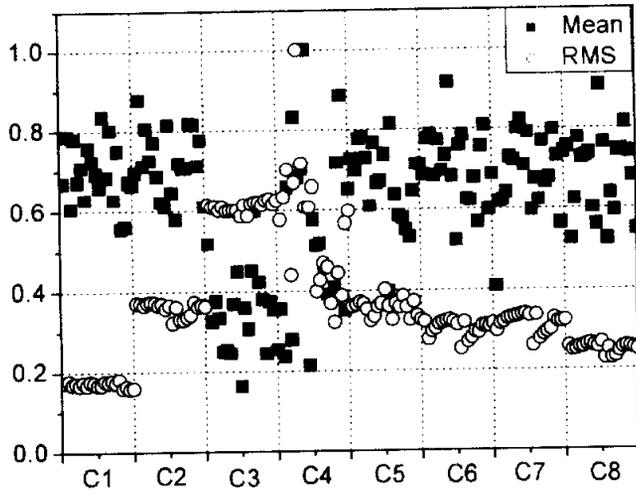
(h) Unbalance

Fig. 5.12. The time waveform signals from machinery fault simulator

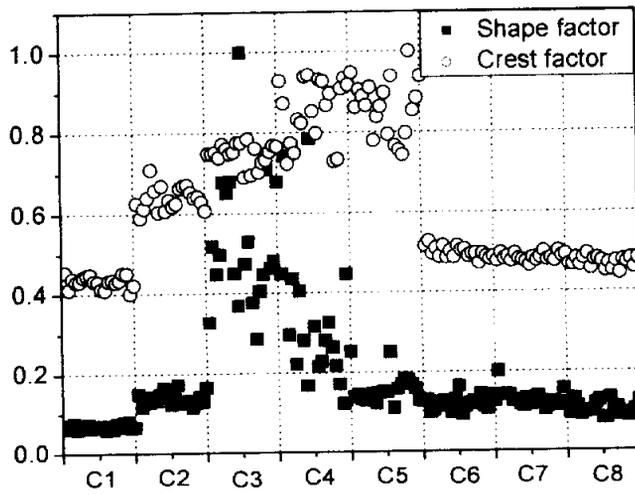
### 5.2.3. 특징 추출

각 결함 상태를 평가하기 위해 취득한 시계열 신호를 Daubeches D10 웨이블릿 변환을 수행하여 level 1부터 level 3(0.625~1.25kHz, 1.25~2.5kHz, 2.5~5kHz)까지 그리고 원 신호의 시간 신호에 대해 각각의 평균(mean), 실효치(RMS), 형상계수(shape factor), 왜도(skewness), 첨도(kurtosis), 파고율(crest factor), Entropy estimator, Entropy error를 구하였다. 총 32가지의 특징 파라미터를 추출하여 SVM의 입력 데이터로 사용하였다.

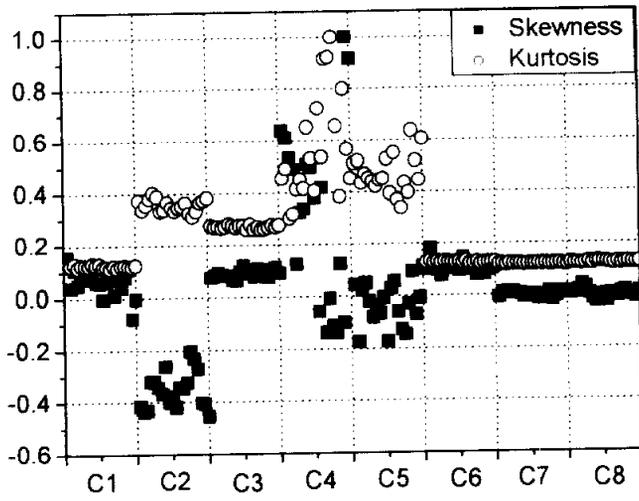
시간 신호에 대한 특징 파라미터 값들을 Fig. 5.13.에 나타내었다.



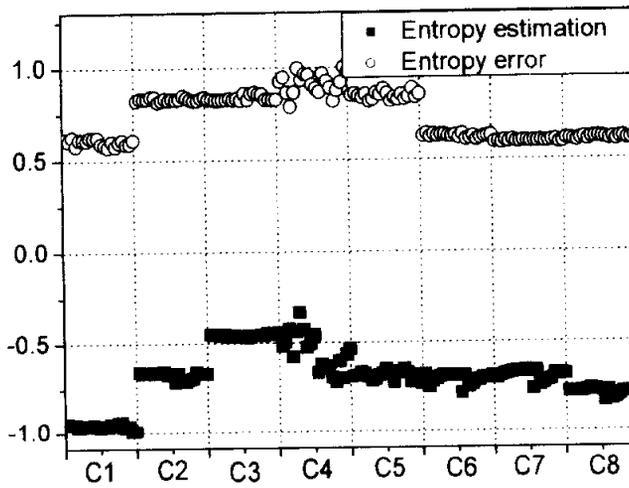
(a) Mean and RMS



(b) Shape factor and crest factor



(c) Skewness and kurtosis



(d) Entropy estimation and error

Fig. 5.13. Feature extraction of the time waveform signals

#### 5.2.4. 시뮬레이션 결과

SVM의 훈련을 위한 데이터로 80개(한 결합 상태당 10개씩), 테스트 데이터로 80개를 사용하였다. 사용한 특징 파라미터로는 각 특징량 사이의 유효성 계수가 높은 8개를 선택하였다. 선택된 특징 파라미터로는 원 신호의 시간 신호에서 entropy error, level 1에서의 entropy error, level 2에서의 RMS, crest factor, entropy estimation, entropy error, level 3에서의 RMS, entropy estimation 이다. Fig. 5.14는 유효성 평가 결과를 보여주고 있다. Table 5.4는 각 특징 파라미터들의 label을 나타내고 있다.

**Table 5.4.** Attribute label of each input feature

Feature	Attribute label			
	Time waveform	Wavelet level 1	Wavelet level 2	Wavelet level 3
Mean	1	9	17	25
RMS	2	10	18	26
Shape factor	3	11	19	27
Skewness	4	12	20	28
Kurtosis	5	13	21	29
Crest factor	6	14	22	30
Entropy estimation	7	15	23	31
Entropy error	8	16	24	32

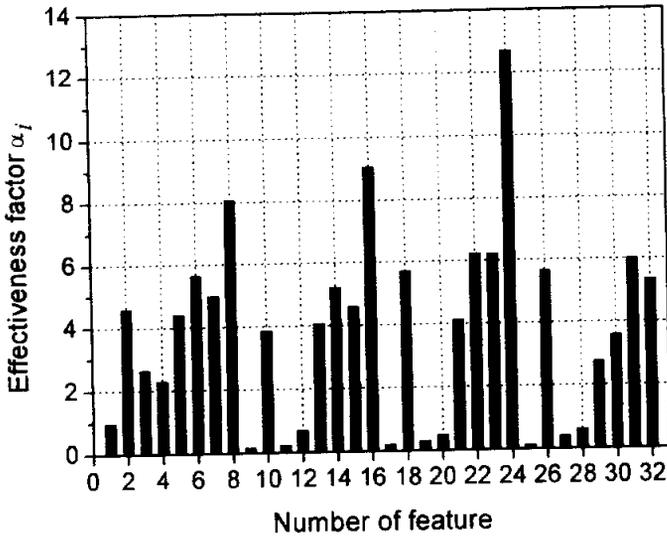


Fig. 5.14. Effectiveness factor of features

SVM의 수행을 위해 사용한 커널 함수로는 linear, polynomial, Gaussian RBF 커널 함수를 사용하였다. 그리고 multi-class 분류를 위한 전략으로는 one-against-one과 one-against-all 방법을 사용하였다. 학습 데이터와 테스트 데이터가 동일할 경우(Training classification)는 커널이나 학습 전략에 관계없이 대부분 100%에 가까운 분류율을 보이고 있다. 그러나 훈련 데이터와 테스트 데이터가 동일하지 않는 경우(Testing classification)를 살펴보면, 대체적으로 one-against-one 방법이 one-against-all 방법보다 더 나은 결과를 보이고 있다. 또한 Gaussian RBF 커널을 사용하였을 때가 다른 커널 함수보다 나은 결과를 보이고 있다. Table 5.5에 커널 함수와 학습 전략에 따른 SVM의 분류 수행 결과를 나타내었다.

**Table 5.5** Fault classification results due to kernel and multi-class classification strategy

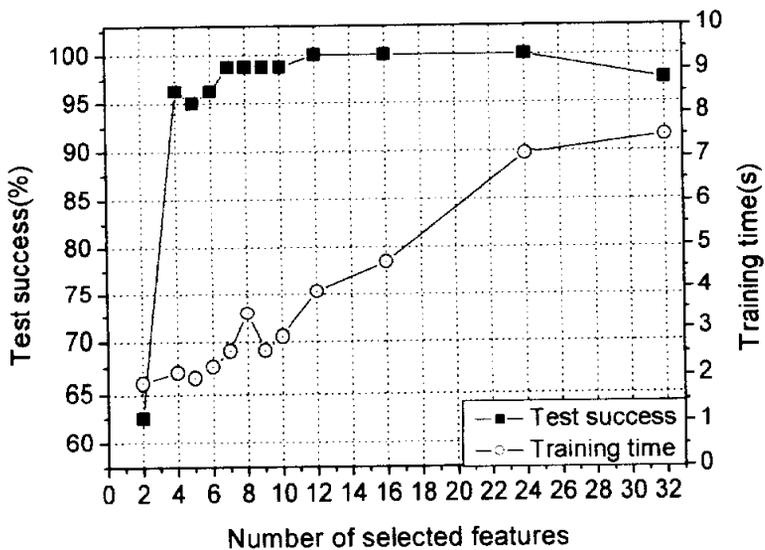
Kernel	Multi-class approach	Classification rate (%)		Number of SVs	Training time (s)
		Training	Testing		
Linear	One vs. one	100	93.75	44	1.25
	One vs. all	98.125	90.00	55	12.10
Polynomial ( $d = 1$ )	One vs. one	100	93.75	41	0.93
	One vs. all	98.125	90.00	55	20.56
Polynomial ( $d = 2$ )	One vs. one	100	92.5	37	0.94
	One vs. all	100	90.00	38	28.31
Polynomial ( $d = 3$ )	One vs. one	100	93.75	37	0.94
	One vs. all	100	88.75	32	22.45
Polynomial ( $d = 4$ )	One vs. one	100	93.75	36	0.98
	One vs. all	100	91.25	36	62.66
Gaussian RBF ( $\sigma = 0.168$ )	One vs. one	100	98.75	43	3.37
	One vs. all	100	92.50	44	9.90

Table 5.6과 Fig. 5.15에는 SVM의 입력 데이터로 사용하는 특징 파라미터 수를 바꿔가면서 수행한 결과를 나타내고 있다. 일반적으로 많이 사용하는 RBF 커널을 사용하였으며 one-against-one 방법을 채택하였다. 그 결과, 파라미터 수가 대략 12~24개 일 경우 100%의 분류율이 보이고 있으며, 훈련 시간은 파라미터의 수에 따라 거의 선형적으로 증가하였다.

Table 5.7은 동일한 조건 하에서 분류화 알고리즘으로 많이 사용하고 있는 SOFM, LVQ, RBF 신경망과 분류 결과를 비교하였으며, 그 결과 SVM이 다른 신경망 알고리즘보다 더 나은 분류율 보이고 있음을 확인하였다.

**Table 5.6** Performance comparison of SVM with feature selection by using RBF kernels and one-against-one method

No. of features	Input features	Kernel Width $\sigma$	Test success (%)	No. of SVs	Training time (s)
2	16,24	0.142	62.50	54	1.87
4	8,16,22,24	0.50	96.25	49	2.09
6	8,16,22,23,24,31	0.152	96.25	41	2.21
8	8,16,18,22,23,24,26,31	0.168	98.75	43	3.37
10	6,8,16,18,22,23,24,26,31,32	0.162	98.75	48	2.85
12	6,7,8,14,16,18,22,23,24,26,31,32	0.145	100	49	3.91
16	2,5,6,7,8,14,15,16,18,21,22,23,24,26,31,32	0.10	100	53	4.62
24	1,2,3,4,5,6,7,8,10,12,13,14,15,16,18,21,22,23,24,26,29,30,31,32	0.28	100	56	7.07
8	Time waveform (1-8)	0.25	98.75	51	3.23
32	All (1-32)	0.60	97.50	67	7.49



**Fig. 5.15.** Performance of SVMs for different number of selected features

**Table 5.7** Classification results of SVM, SOFM, LVQ and RBF networks

Classifier	SOFM	LVQ	RBF	SVM
Success rate (%)	93	93	89	98.75
Network structure	80-54	80-40	80-35-42	43

## 6. 결 론

본 연구에서는 회전기계의 상태를 분류하고 결함을 진단함에 있어서 현실적인 문제인 전문적인 지식을 소유한 진단 전문가의 부족과 기계 설비의 상태 감시 및 진단의 자동화를 위하여 패턴 인식분야에서 우수한 성능을 보이고 있는 SVM 알고리즘을 이용한 상태 감시 및 진단 알고리즘을 제안하였다.

그리고 제안한 알고리즘으로 실제 생산되고 있는 냉장고용 소형 압축기와 인위적인 결함을 부여할 수 있는 실험장치에서 취득한 데이터로 그 유용성을 평가하여 만족스러운 결과를 얻었다. 또한 기존의 패턴 인식에 많이 사용하고 있는 인공 신경망과 비교하였을 때 분류율에서 더 양호한 결과를 보이고 있음을 확인하였다.

SVM 알고리즘의 성능과 직접적으로 관련이 있는 입력 파라미터를 위한 특징 추출 기법과 비선형적인 실제적인 문제를 해결하기 위한 커널 함수, 그리고 다진 분류를 위한 전략들을 검토하였다. 그 결과, 커널 함수로는 RBF 커널을 사용하였을 때, 전략으로는 one-against-one 방법을 사용하였을 때가 가장 우수한 분류 결과를 얻었다.

따라서 거동 기반에 의한 기계 설비의 상태감시 및 진단의 관점에서 볼 때, 본 연구에서 제안된 알고리즘을 사용함으로써 기존의 방법보다 더 나은 정확도로 인하여 잘못된 판단, 즉 오 진단의 횟수를 줄임으로써 보전시간과 비용을 줄일 수 있고, 생산성 향상에 도움을 줄 수 있을 것으로 생각된다.

## 참고 문헌

- (1) V.N. Vapnik, The Nature of Statistical Learning Theory, Springer, Berlin, 1995
- (2) M.A. Hearst, B. Scholkopf, S. Dumais, E. Osuna, J. Platt, 1998, "Trends and Controversies-Support Vector Machines," IEEE Intelligent System, Vol. 13, No. 4, pp. 18-28
- (3) N. Cristianini, J.S. Taylor, "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods," Cambridge University Press, 2000.
- (4) 황원우, 고명환, 양보석, "SVM을 이용한 버터플라이 밸브의 캐비테이션 상태감시", 한국소음진동공학회 논문집, 2004.(게재 예정)
- (5) K.R. Müller, S. Mika, G. Rätsch, K. Tsuda, B. Schölkopf, An introduction to kernel- based learning algorithm, IEEE Transaction on Neural Network 12 (2) (2001) 181-201.
- (6) M. Ge, R. Du, G. Zhang, Y. Xu, "Fault diagnosis using support vector machine with an application in sheet metal stamping operations", Mechanical Systems and Signal Processing
- (7) D.S. Broomhead, D.Lowe, "Multivariable functional interpolation and adaptive network", Complex System 2, 1998, pp. 321-355
- (8) V.C. Srinivasa, G. Joydeep, "Scale based clustering using the radial basis function", IEEE Trans. Neural Network, 1996, pp. 1250-1261
- (9) W. Wang, Z. Xu, W. Lu, X. Zhang, " Determination of the spread parameter in the Gaussian kernel for classification and regression", Proceeding of Neurocomputing, 2002
- (10) J. Platt, 1999, "Fast Training of Support Vector Machines using Sequential

- Minimal Optimization,” In B. Scholkopf, C.J.C. Burges, A.J. Smola, “Advances in Kernel Methods-Support Vector Learning,” MIT Press, pp. 336-342
- (11) S.S. Keerthi, S.K. Shevade, 2002, “SMO Algorithm for Least Squares SVM Formulations,” Control Division Technical Report CD-02-8.
- (12) C.W. Hsu, C.J. Lin, A comparison of methods for multiclass support vector machines, IEEE Transaction on Neural Networks 13 (2) 415–425, 2002.
- (13) S. Knerr, L. Personnaz, G. Dreyfus, Single-layer learning revisited: A stepwise procedure for building and training a neural network, in Neurocomputing: Algorithms, Architectures and Applications, J. Fogelman, Ed. Springer-Verlag, New York, 1990.
- (14) U. Kre, et al., Pairwise classification and support vector machines, in Advances in Kernel Methods- Support Vector Learning, B. Scholkopf, C.J.C. Burges, A.J. Smola, Eds. MIT Press, Cambridge, 255–268, 1999.
- (15) J.C. Platt, N. Cristianini, J. Shawe-Taylor, Large margin DAG’s for multiclass classification, Advances in Neural Information Processing Systems 12 (2000) 547–553.
- (16) F. Schwenker, Hierarchical support vector machines for multi-class pattern recognition, Proceeding of 4th International Conference on Knowledge-Based Intelligent Engineering Systems & Allied Technologies, pp. 561–565, 2000.
- (17) 양보석, “회전기계의 진동- 해석, 평가, 설계 및 대책”, 인터비전, 2002.
- (18) 양보석, “진동법에 의한 설비 진단의 실제”, 일오출판사, 2000.
- (19) 안경룡, “인공신경망을 이용한 회전 기계의 고장진단”, 박사학위논문, 부경대학교, 2002
- (20) T. Han, “Feature Extraction of Vibration Signal for Machinery Condition Monitoring”, 석사학위논문, 부경대학교, 2002

- (21) G.N. Saridis, "Stochastic processes, estimation, and control", John Wiley & Sons, Inc., pp. 57-59
- (22) 강창언, 오용선, 강민구, "정보공학-코딩이론과 정보이론의 접목", 진영사, pp. 277
- (23) 박상희, "생체신호처리 및 응용", 에드텍, pp. 421-428
- (24) 김병욱, "Wavelet 변환을 이용한 회전 기계의 이상진동진단", 석사학위논문, 부경대학교, 2000.
- (25) L.B. Jack, A.K. Nandi, Fault detection using support vector machines and artificial neural networks, augmented by genetic algorithms, *Mechanical Systems and Signal Processing* 16 (2-3) (2002) 373-390.
- (26) 황원우, 한천, 양보석, "SVM을 이용한 냉장고용 왕복동 압축기의 상태 분류", 한국동력기계공학회, 추계학술대회, pp. 30-36, 2003.
- (27) 황원우, 양보석, "Multi-class SVM을 이용한 회전기계의 결함진단", 한국소음진동공학회, 추계학술대회, pp. 537-543, 2003.

## 감사의 글

먼저 이 논문이 나오기까지 부족한 저에게 많은 지도와 학문의 길을 인도하여 주신 저의 지도교수 양보석 교수님의 은혜에 진심으로 감사드립니다. 또한 본 논문의 완성도를 높이기 위해 많은 조언을 해 주신 김천덕 교수님, 배동명 교수님께 깊이 감사드립니다.

2000년 봄에 연구실에 들어와서 졸업하는 지금의 순간까지 저에게 관심과 도움을 주신 여러 선배님 및 후배님들의 모습이 떠오릅니다. 항상 따뜻하게 좋은 말과 웃음을 주시는 공영모 선배님, 친형처럼 언제나 부담 없이 다가가 의지할 수 있는 김영찬 선배님, 짧은 기간이었지만 많은 조언을 해주신 말형 같은 임동수 선배님, 늘 자상한 미소로 저를 대 해주신 안경룡 선배님, 만능 스포츠맨이면서 다양한 지혜를 가진 흥건족의 족장님인 김용한 선배님, 멀리 거제도에서 열심히 근무하시는 김병욱 선배님, 포스콘에서 열심히 연구하고 계신 오용민 선배님, 연구실의 실장님이며 제가 가장 귀찮게 한 송진대 선배님, 석호일 선배님, 김용수 선배님 그리고 대학원 동기인 하종룡, 김광진, 구형은, 채상일, 마지막으로 앞으로 실험실을 이끌어 나갈 차세대 주역인 손종덕군 및 칸도리 3인방 심민찬, 이재갑, 김선화군에게 따뜻한 감사의 말을 전합니다.

무엇보다도 지금까지 변함없는 정성으로 키워주시고 보살피 주신 아버님, 어머님, 그리고 형에게 사랑한다는 말을 전하고 싶습니다. 그리고 대학원에 들어와서 바쁘다는 핑계로 자주 만나주지 않는데도 불평 한번 안하고 항상 힘이 되어준 내 짝꿍 난령에게도 사랑한다는 말을 전하고 싶습니다.

다시 한번 더 교수님을 비롯한 사모님 그리고 선·후배님께 감사의 말을 전하며 이 논문을 바칩니다.