

Multi-class SVM을 이용한 회전기계의 결함 진단

Fault Diagnosis of Rotating Machinery Using Multi-class Support Vector Machines

황 원 우* · 양 보 석†

Won-Woo Hwang and Bo-Suk Yang

(2004년 12월 3일 접수 : 2004년 2월 25일 심사완료)

Key Words : Fault Diagnosis(결함진단), Kernel Function(커널함수), Support Vector Machine(SVM), Rotating Machinery(회전기계), Vibration Signal(진동신호)

ABSTRACT

Condition monitoring and fault diagnosis of machines are gaining importance in the industry because of the need to increase reliability and to decrease possible loss of production due to machine breakdown. By comparing the vibration signals of a machine running in normal and faulty conditions, detection of faults like mass unbalance, shaft misalignment and bearing defects is possible. This paper presents a novel approach for applying the fault diagnosis of rotating machinery. To detect multiple faults in rotating machinery, a feature selection method and support vector machine (SVM) based multi-class classifier are constructed and used in the faults diagnosis. The results in experiments prove that fault types can be diagnosed by the above method.

기호설명

- b : 한계값(threshold value)
- E : 예측 오차
- $K(\mathbf{x}, \mathbf{y})$: Kernel 함수(= $\phi(\mathbf{x}) \cdot \phi(\mathbf{y})$)
- L : Lagrangian
- $(\mathbf{w} \cdot \mathbf{x})$: 벡터 \mathbf{w} 와 \mathbf{x} 의 내적
- \mathbf{w} : 가중치 벡터(weight vector)
- $\|\mathbf{w}\|$: 벡터 \mathbf{w} 의 놈(norm)
- \mathbf{x} : 입력 벡터(input vector)
- y_i : 출력 값(+1 또는 -1)
- $\phi(\mathbf{x})$: 특징공간으로의 변환 함수
- α : Lagrange multipliers
- σ : RBF kernel의 폭(width)

1. 서 론

산업의 발전과 기술의 진보에 따라 각종 산업용 회전기계는 대용량, 고속화, 고 하중으로 되고, 이는 가혹한 운전조건으로 작용하여 많은 스트레스를 기계에 부가하게 된다. 제품의 생산 효율 및 품질의 중요성과 아울러 안정적인 기능 유지, 보수 및 진단에 대한 인식이 높아지고 있으며 이미 커다란 경제적인 영역을 형성하고 있다.⁽¹⁾

회전기계는 발전플랜트 등 각종 산업 현장에서 광범위하게 사용되고 있으며 중요한 역할을 수행하기 때문에, 이상이 발생했을 때 즉각적인 고장 원인의 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

† 책임저자 : 정희원, 부경대학교 기계공학부
E-mail : bsyang@pknu.ac.kr
Tel : (051) 620-1604, Fax : (051) 620-1405
* 부경대학교 대학원 기계공학부

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 다양한 연구가 여러 방면에서 이루어지고 있다.^(2~5)

SVM알고리즘의 이론은 1960년대 후반에 통계학적인 학습이론을 기초로 하여 Vapnik에 의해 처음 제안되었으나,⁽⁶⁾ 당시 컴퓨터의 계산능력 부족으로 인해 1990년 중반부터 다양한 분야에 적용되고 있다. 그러나 설비진단에의 적용은 최근에 몇몇 연구자에 의해 시도^(7~9)되고 있을 뿐이다.

이 연구에서는 회전기계에서 발생할 수 있는 결함을 진단하기 위해 support vector machines(SVM) 알고리즘을 이용한 회전기계의 결함진단 시스템을 제안하고, 인위적인 결함을 부여할 수 있는 실험 장치로부터 취득한 진동신호를 이용하여 제안된 알고리즘의 유용성을 확인하였다.

2. Support Vector Machines^(10, 11)

기본적인 SVM은 이진분류문제에 널리 이용되며, hyperplane을 중심으로 한쪽은 positive 클래스, 다른 한쪽은 negative 클래스로 나눈다. $(\mathbf{x}_i, y_i) (i=1, \dots, N)$ 를 훈련데이터 집합 S , 데이터 $x_i \in R^N$ 가 클래스 $y_i \in \{-1, 1\}$ 에 속한다고 하면, 두 데이터 집합의 경계가 되는 hyperplane은 식 (1)과 같이 정의된다.

$$\mathbf{w} \cdot \mathbf{x} + b = 0, \mathbf{w} \in R^N, b \in R \quad (1)$$

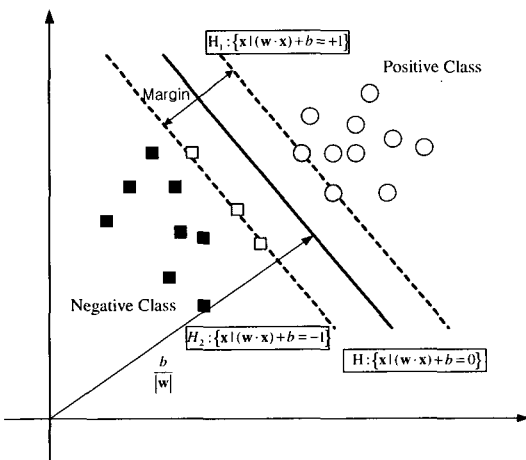


Fig. 1 Binary classification of dataset by SVM

여기서, \mathbf{w} 는 두 데이터 집합의 경계가 되는 가중치 벡터, \mathbf{x} 는 N 차원의 입력벡터, b 는 한계값이다.

Fig.1은 다른 두 데이터 집합이 경계가 되는 hyperplane H 에 의해 분리되는 것을 보이고 있다. SVM은 경계와 각 클래스에 속한 가장 인접한 데이터와의 거리(margin)가 최대가 되게 한다. 그림에서 경계와 가장 인접한 회색 원과 사각형 데이터 점을 support vector(SV)라 하며, 이 SV에는 두 클래스를 구분할 수 있는 모든 정보들이 포함되어 있기 때문에, 이를 제외한 나머지 데이터는 필요 없게 되어 폐기된다. 따라서 데이터의 overfitting과 테스트 시간이 상대적으로 모든 데이터를 사용하는 다른 알고리즘에 비하여 빠르게 된다. 새로운 데이터에 대한 결정함수는 식 (2)와 같다.

$$f(x) = \text{sign}(\mathbf{w} \cdot \mathbf{x} + b) \quad (2)$$

두 hyperplane H_1 과 H_2 사이의 거리를 구하면 식 (3)과 같으며, 이 값이 최대가 되어야 한다.

$$\text{margin} = \frac{2}{\|\mathbf{w}\|} \quad (3)$$

식 (2)와 (3)을 정리하면 식 (4)와 같은 최적화문제에 귀착된다.

$$\begin{aligned} &\text{Minimize } \tau(\mathbf{w}) = 1/2\|\mathbf{w}\|^2 \\ &\text{subject to } y_i(\mathbf{w} \cdot \mathbf{x} + b) \geq 1, i=1, 2, \dots, N \end{aligned} \quad (4)$$

식 (4)를 풀기 위하여 Lagrange multipliers $\alpha_i \geq 0 (i=1, 2, \dots, N)$ 의 개념을 도입하면, Lagrangian은 식 (5)와 같이 된다.

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2}\|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i y_i (\mathbf{w} \cdot \mathbf{x}_i + b) + \sum_{i=1}^N \alpha_i \quad (5)$$

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

$$\mathbf{w} = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i, \quad \sum_{i=1}^N \alpha_i y_i = 0 \quad (6)$$

식 (6)을 식 (5)에 대입하여 정리하면,

$$\begin{aligned} &\text{Maximize} \\ &L_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \end{aligned}$$

Subject to

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

$$\sum_{i=1}^N \alpha_i y_i = 0 \tag{7}$$

식 (6)을 사용하여 결정함수인 식 (2)를 재정의하면, 식 (8)과 같이 된다.

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i (\mathbf{x}_i \cdot \mathbf{x}) + b \right) \tag{8}$$

따라서, Lagrange multipliers α_i 와 한계값 b 를 구하게 되면, 새로운 입력 데이터 \mathbf{x} 를 분류할 수 있다. 여기서 미지의 파라미터인 α_i, b 는 SVM의 학습 알고리즘인 sequence minimize optimization(SMO)^(12,13)으로부터 구할 수 있다.

지금까지는 입력 공간이 선형적으로 분리가 가능한 경우만을 고려하였다. 그러나 실제로 많은 경우, 선형적으로 두 클래스를 구별할 수 없다. 하지만 N 차원 입력공간의 데이터를 고차원의 특징 공간(Q 차원)으로 변환함으로써 선형적으로 구별할 수 있으며 (Fig. 2), 이를 위해 kernel 함수가 이용된다.

변환함수는 식 (9)와 같이 정의된다.

$$\mathbf{s} = \Phi(\mathbf{x}) \tag{9}$$

여기서, $\mathbf{x} \in R^N, \mathbf{s} \in R^Q$ 이다.

식 (9)를 결정함수 식 (8)에 대입하면 다음과 같다.

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i (\Phi(\mathbf{x}) \cdot \Phi(\mathbf{x}_i)) + b \right) \tag{10}$$




Fig. 2 Transformation to linear feature space from nonlinear input space

결정함수를 kernel함수 $K(\mathbf{x}, \mathbf{y}) = \Phi(\mathbf{x}) \cdot \Phi(\mathbf{y})$ 로 대체하면 식 (11)과 같이 된다.

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \right) \tag{11}$$

따라서, 식 (11)을 통하여 SVM이 비선형적인 입력공간을 선형적인 특징공간으로 변환하여 분류할 수 있다. 일반적으로 사용되는 kernel함수로는 RBF kernel, Polynomial kernel, Perceptron, Linear 등이 있다.

3. Multi-class SVM의 전략

기본적으로 SVM은 이진 분류를 수행하며, 여러 클래스를 가지는 실제 응용분야에의 적용에는 한계가 있다. 그래서 이를 극복하기 위한 방안으로 이진 분류의 조합에 대한 전략들이 제시되었다. 대표적인 전략으로는 one-against-all,⁽¹⁴⁾ one-against-one,^(15, 16) directed acyclic graph⁽¹⁷⁾ 및 binary tree⁽¹⁸⁾ 등과 같은 것들이 있다. 여기에서는 one-against-all, one-against-one 기법을 적용하였으며 두 방법에 대해 분류성능을 비교, 검토하였다.

3.1 One-against-all 기법⁽¹⁴⁾

이 방법은 초기 multi-class 분류화를 수행하기 위해 사용된 모델이다. k 개의 상태를 분류하기 위해 $k-1$ 개의 SVM이 필요하며, 학습데이터는 $k-1$ 개 모두

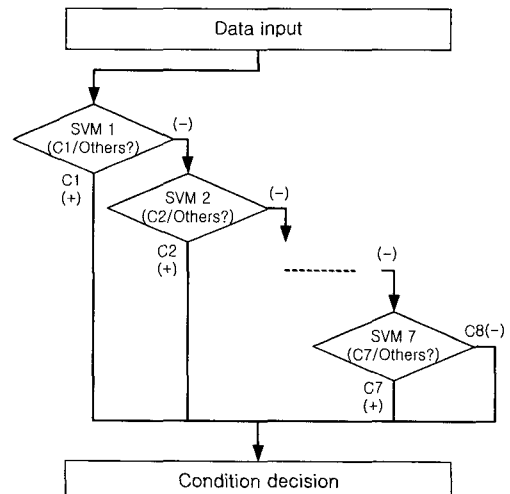


Fig. 4 One-against-all approach

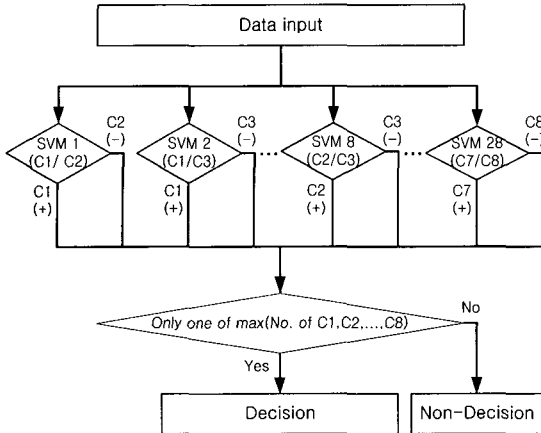


Fig. 5 One-against-one approach

동일하나 상태의 소속을 나타내는 라벨은 수행되는 SVM에 따라 달라진다. 가령, i 번째 SVM은 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 SVM의 수행 후 그 결과값이 +1 값을 도출한 SVM에서 그 상태를 판별하게 된다.

3.2 One-against-one 기법^(15, 16)

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

4. 결함 진단 시스템의 구성

4.1 실험 장치 및 데이터 취득

Fig. 6의 실험장치는 인위적으로 시스템에 결함을 인가할 수 있는 장치로서 3상 유도 전동기로 구동되며 커플링, 베어링, 디스크, 축으로 구성되어 있다. 결함은 커플링 부분의 편심(parallel) 및 편각(angular) 정렬불량, 베어링 결함(내륜, 외륜, 볼, 및 복합 결




Fig. 6 Machinery fault simulator

Table 1 Description of each fault condition

Condition	Label	Description	
Normal	C1	No fault	
Bearing fault	Outer race	C2	One spalling
	Inner race	C3	One spalling
	Ball	C4	One spalling
	Complex	C5	Outer, inner, ball
Misalignment	Angular	C6	0.7°
	Parallel	C7	2 mm
Unbalance	C8	578 g·mm	

함), 디스크의 불평형, 정상상태의 총 8가지이다. Table 1은 실험장치에 인가한 결함의 종류와 그에 따른 라벨(label), 그리고 결함에 대한 간략한 설명과 정량적인 크기를 나타내었다.

진동신호는 반부하측 베어링 하우징 상단에 부착된 가속도계를 이용하여 최대주파수 5 kHz, 데이터 수 16384개로 하여 운전속도 1800rpm (30Hz)에서 각 상태에 대하여 각각 연속적으로 20개씩 총 160개의 시간신호를 취득하였다.

각 상태의 스펙트럼을 검토하면, 정상상태의 진동신호는 잔류 불평형과 베어링, 커플링, 전동기 등의 영향으로 각 차수의 조화성분과 각 요소의 특징 주파수들이 낮은 진폭으로 나타난다. 그러나 불평형을 부과하였을 경우엔 1x (30 Hz) 성분이 증가하고 기타 성분들은 거의 변화가 없다. 편각 정렬 불량인 경우, 1x, 2x, 3x 성분 등의 회전주파수의 저차 조화성분이 현저히 증가하고, 편심 정렬불량의 경우는 2x, 3x 성분이 증가하였다. 베어링 외륜 결함은 외륜통과주파수인 104.7 Hz 성분이 현저하고 또한 충격 가진으로 인한 고주파 대역의 각 요소의 공진 성분들이 나타나고 있다. 내륜 결함에서는 내륜 통과주파수인 162.2 Hz가 나타난다. 볼 결함의 경우는 볼 자전속도의 2배

성분인 142.44 Hz 성분이 존재한다. 복합 결함일 경우의 베어링의 진동 신호는 많은 주파수 성분들을 포함하고 있고 고주파 영역에서 충격 가진으로 인한 공진 진동이 발생하고 있다.

4.2 특징 추출


센서로부터 취득된 시계열 신호는 시간상 연속적으로 취득된 것이 아니라 통계적인 표본 값이므로 시스템의 상태변화를 정확하게 표현하기 어렵다. 따라서 신호에 대하여 통계적인 처리기법을 이용하여 처리 분석하고 일정한 통계적 규칙을 갖고 있는 통계량으로 시계열 신호의 특징을 표현하여야 한다.⁽¹⁶⁾ 시계열 신호의 특징을 표현할 수 있는 파라미터는 여러 가지가 있으나, 본 연구에서는 원 신호(raw signal)에 대한 평균(mean), 실효치(RMS), 형상계수(shape factor), 왜도(skewness), 첨도(kurtosis), crest factor, entropy estimation 및 entropy error와 같이 8가지의 통계량을 추출하였다. 또한 시간신호의 Daubeches-10 (db-10) wavelet 변환을 level 3까지 수행하고 각

level에 대한 위의 8가지 통계값을 추출하여 총 32개를 기본 파라미터로 선정하였다.

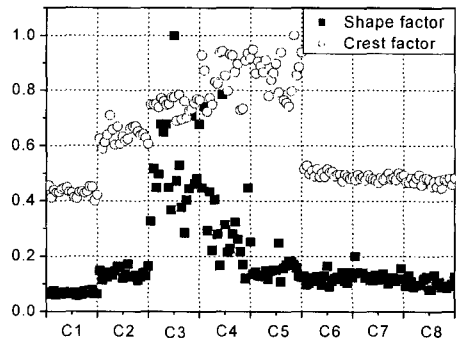
Table 2에는 기본 파라미터 32개와 그에 대한 라벨을 나타내었다. 이 라벨은 통계적 특징 파라미터의 번호로 사용하며 유효성 계수의 결과를 나타낸 Fig. 8의 파라미터 번호와 관계된다.

Table 2 Attribute label of each input feature


Feature	Attribute label			
	Time	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



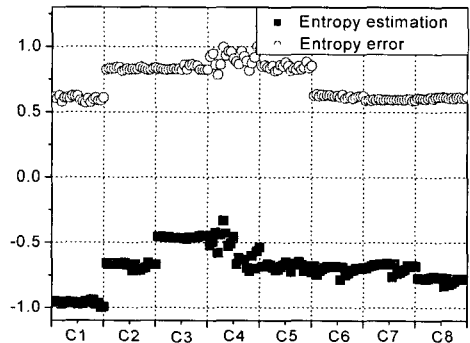
(a) Mean and RMS



(b) Shape factor and crest factor



(c) Skewness and kurtosis



(d) Entropy estimation and entropy error

Fig. 7 Feature extraction of the time waveform signal

Fig. 7은 원 신호에 대한 통계적인 특징 파라미터를 각 결합 별로 도시하여 각 결합에 따라 8가지 특징 파라미터의 값들이 어떻게 변화하는가를 보여 주고 있다.

4.3 특징 선택

일반적으로 많은 파라미터의 사용은 SVM의 성능을 저하시킬 수 있으며 학습 및 테스트 시간을 길게 하므로 총 32개의 파라미터를 대상으로 아래의 방법을 통해 유효성 평가를 실시하여 유효성 계수가 높은 5~13개 정도의 파라미터를 SVM의 입력 파라미터로 선택하였다.⁽¹⁵⁾

유효성 평가 방법은 다음과 같다.

단계 1: 동일한 상태 집합에서의 각각의 데이터간의 상대 거리 $d_{i,j}$ 를 계산한다.




Fig. 8 Effectiveness factor of features

$$d_{i,j} = \frac{1}{N \times (N-1)} \sum_{m,n=1}^N |p_{i,j}(m) - p_{i,j}(n)|$$

단계 2: 다른 상태의 데이터 집합에서의 각각의 데이터간의 상대 거리 $d'_{i,j}$ 를 계산한다.

$$d'_{ai} = \frac{1}{M \times (M-1)} \sum_{m,n=1}^M |p_{ai,m} - p_{ai,n}|$$

단계 3: 각 파라미터의 유효성 계수(상대거리비) α_i 를 계산한다.

$$\alpha_i = d'_{ai} / d_{ai}$$

여기서, $m, n = 1, 2, \dots, N, m \neq n, P_{i,j}$: 고유치, i : 특징 지수, j : 상태 지수, N : 데이터 수, M : 특징 수이다.

Fig. 8에 총 32개의 기본 파라미터에 대한 유효성 계수를 구한 결과를 도시하였다. Wavelet level 2의 entropy error의 경우, 유효성 계수의 값이 크며 이는 32개의 파라미터 중에서 동일한 상태 데이터 사이의 분산성은 작으며 다른 상태의 데이터 사이의 분산성이 크다는 것을 의미한다. 이 연구에서는 유효성 계수가 가장 큰 순으로 8개의 특징 파라미터를 이용하였다.

4.4 진단 시스템의 구성

Fig. 9는 이 연구에서 제안된 진단 시스템의 전체 구조를 개략적으로 나타낸다.

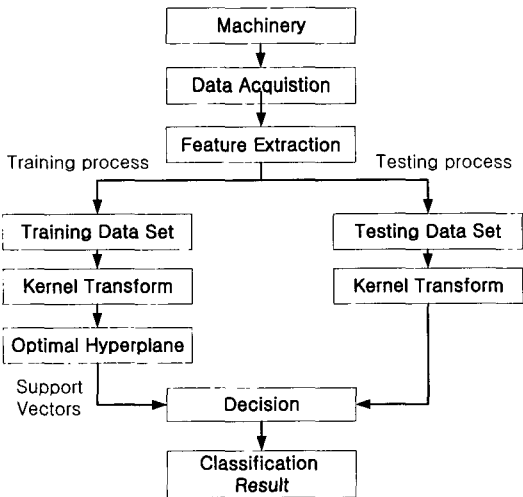


Fig. 9 Block diagram of SVM classifier system

5. Simulation 결과

5.1 학습 및 테스트 데이터의 구성

취득한 총 160개의 데이터 중에서 학습데이터로 각 결합에 대해 10개씩 총 80개를 사용하였으며, 나머지 80개를 테스트 데이터로 사용하였다. 또한 입력 벡터를 구성함에 있어 유효성 계수가 큰 순서로 하여 2~32 차원까지 구성하였다.

5.2 학습 및 테스트 결과

이 연구에서 사용한 kernel 함수와 그에 대한 정의를 Table 3에 나타내었다. Table 4는 유효성 계수가 높은 특징 파라미터 8개를 선택하여 kernel 함수 및 전략에 따른 학습 및 테스트 데이터의 분류율을 나타내

고 있다. 학습 데이터의 분류율은 kernel 함수와 multi-class 전략에 관계없이 거의 모두 100%의 양호한 분류율을 보이지만, 테스트 데이터의 분류율은 Gaussian RBF kernel이 다른 kernel에 비해 좀 더 양호한 분류율을 보인다. 그리고 전반적으로 one-against-one 방법이 one-against-all 방법보다 나은 결과를 보이고 있다. 일반적으로 kernel함수의 선정은 사전에 결정하는 것이 불가능하므로 적절한 함수를 선정

하는 것이 양호한 분류율을 얻기 위해서는 매우 중요함을 알 수 있다. 또한 Fig. 10은 선택한 특징 파라미터수에 따른 분류율과 학습시간을 나타내고 있다.

6. 결 론

이 연구에서는 이진 분류에 탁월한 분류성능을 가진 SVM 알고리즘을 조합한 Multi-class SVM을 이용한 회전기계의 결함진단 시스템을 제안하였다. 진동 가속도신호의 정상 특징을 통계적 모멘트를 이용하여 총 32가지의 특징을 추출하였으며, 이들 특징 중에서 유효성 계수가 큰 특징을 선정하고 이를 입력 데이터로 하여 분류기를 훈련(학습)하여 회전기계의 다양한 결함 상태를 분류하였다. 제안한 시스템을 회전기계의 결함진단에 적용한 결과 입력 파라미터로서는 유용성 계수가 높은 6~24개를 사용하고, one-against-one 방법과 Gaussian RBF kernel을 사용하였을 때 거의 100%에 가까운 양호한 결과를 얻었다.

따라서 제안된 시스템은 회전기계의 자동 상태감시 및 진단시스템과 실시간 실행을 가능하도록 함으로서 심각한 고장에 이르기 전에 문제를 사전에 탐지하고 즉시 보수작업의 스케줄을 설정하는데 크게 기여할 수 있을 것으로 기대된다.

참 고 문 헌

- (1) Williams, J. H., Davies A. and Drakes, P. R., "Condition-based Maintenance and Machine Diagnostics," Chapman & Hall, 1994.
- (2) Lim, D. S., Yang, B. S. and Kim, D.J., 2000, "An Expert System for Vibration Diagnosis of Rotating Machinery Using Decision Trees," International Journal of Condition Monitoring and Diagnostic Engineering. Management (COMADEM), Vol. 3, No. 4, pp. 31~36.
- (3) 백두진, 이용복, 김승중, 김창호, 장건희, 2003, "산업용 터보기기 결함진단을 위한 복합적 데이터베이스 구조의 퍼지전문가시스템," 한국소음진동공학 회논문집, 제 13 권, 제 9 호, pp. 703~712.
- (4) Yang, B.S., Kim, K. and Rao, Raj B.K.N., 2002, "Condition Classification of Reciprocating Compressors Using RBF Neural Network,"

Table 3 Formulation for used kernel functions

Kernel	$K(x, y)$
Linear	$x \cdot y$
Polynomial	$(x \cdot y + 1)^d$
Gaussian RBF	$\exp\{-\ x - y\ ^2 / 2\sigma^2\}$

Table 4 Classification results due to kernel and multi-class classification strategy

Kernel	Multi-class approach	Classification rate (%)	
		Training	Testing
Linear	One vs. one	100	93.75
	One vs. all	98.125	90.00
Polynomial ($d=1$)	One vs. one	100	93.75
	One vs. all	98.125	90.00
Polynomial ($d=2$)	One vs. one	100	92.5
	One vs. all	100	90.00
Polynomial ($d=3$)	One vs. one	100	93.75
	One vs. all	100	88.75
Polynomial ($d=4$)	One vs. one	100	93.75
	One vs. all	100	91.25
RBF ($\sigma=0.168$)	One vs. one	100	98.75
	One vs. all	100	92.50

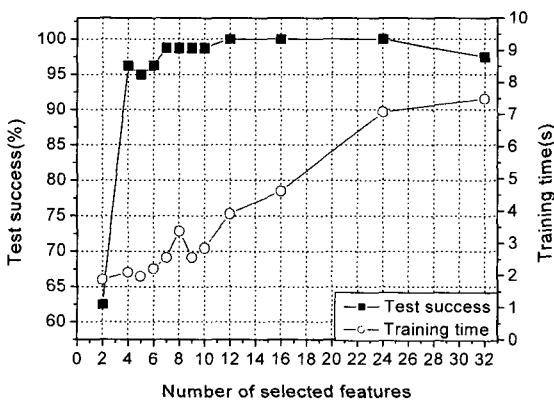


Fig. 10 Performance of SVMs for different number of selected features

International Journal of COMADEM, Vol. 5, No. 4, pp. 12~20.

(5) 이종민, 황요하, 김승중, 송창섭, 2003, "AR계수를 이용한 Hidden Markov Model의 기계상태진단 적용," 한국소음진동공학회논문집, 제 13 권, 제 1 호, pp. 48~55.

(6) V. N. Vapnik, 1982, *Estimation of Dependences Based on Empirical Data*, Springer-Verlag.

(7) Jack, L. B. and Nandi, A. K., 2002, "Fault Detection using Support Vector Machines and Artificial Neural Networks, Augmented by Genetic Algorithms," *Mechanical Systems and Signal Processing*, Vol. 16, No. 2-3, pp. 373~390.

(8) 황원우, 고명환, 양보석, 2004, "SVM을 이용한 버터플라이벨브의 캐비테이션 상태감시," 한국소음진동공학회논문집, 제 14 권 제 2 호, pp. 119~127.

(9) Yang, B. S., Hwang, W. W., Kim, D. J. and Tan, A. C., 2005, "Condition Classification of Small Reciprocating Compressor for Refrigerators using Artificial Neural Networks and Support Vector Machines," *Mechanical Systems and Signal Processing*, Vol. 19, pp. 371~390.

(10) 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.

(11) N. Cristianini, J. S. Taylor, 2000, *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*, Cambridge University Press.

(12) Platt, J., 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

(13) Keerthi, S. S. and Shevade, S. K., 2002, "SMO Algorithm for Least Squares SVM Formulations," *Control Division Technical Report CD-02-8*.

(14) Hsu, C. W. and Lin, C. J., 2002, "A Comparison of Methods for Multiclass Support Vector Machines," *IEEE Transaction on Neural Networks*, Vol. 13, No. 2, pp. 415 ~425.

(15) Knerr, S., Personnaz, L. and Dreyfus, G., 1990, Single-layer Learning Revisited: A Stepwise Procedure for Building and Training a Neural Network, in *Neuro-computing: Algorithms, Architectures and Applications*, J. Fogelman, Ed. Springer-Verlag, New York.

(16) Kreßel, U., 1999, 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, pp. 255~268.

(17) Platt, J. C., Cristianini, N. and Shawe-Taylor, J., 2000, "Large Margin DAG's for Multiclass Classification," *Advances in Neural Information Processing Systems*, Vol. 12, pp. 547~553.

(18) Schwenker, F., 2000, "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.

(19) Yang, B. S., Han, T. and An, J. L., 2004, "ART-Kohonen Neural Network for Fault Diagnosis of Rotating Machinery," *Mechanical Systems and Signal Processing*, Vol. 18, No. 3, pp. 645~657.